

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra obchodu a financí



Diplomová práce

Vývoj spotřeby piva v České republice

Lukáš Bujas

© 2020 ČZU v Praze

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Lukáš Bujas

Hospodářská politika a správa
Podnikání a administrativa

Název práce

Vývoj spotřeby piva v České republice

Název anglicky

Development of beer consumption in the Czech Republic

Cíle práce

Hlavním cílem diplomové práce je na základě kvantitativní analýzy vyhodnotit vývoj a provést prognózu spotřeby piva v České republice pro následující období.

Mezi dílčí cíle práce patří:

- a) definování determinantů, které mohou mít vliv na vývoji spotřeby
- b) odhad a verifikace ekonometrického modelu
- c) strukturální analýza determinantů působících na spotřebu piva
- d) verifikace prognostických schopností

Metodika

- 1) Ekonomická teorie
- 2) Tvorba ekonomického modelu
- 3) Tvorba ekonometrického modelu
- 4) Sběr, zpracování a analýza vstupních dat
- 5) Odhad parametrů ekonometrického modelu
- 6) Ekonomické ověření modelu
- 7) Statistické a ekonometrické ověření
- 8) Aplikace ekonometrického modelu

Doporučený rozsah práce

60-80

Klíčová slova

ekonometrie, ekonometrický model, analýza, pivo, spotřeba, vývoj, cena

Doporučené zdroje informací

BASAŘOVÁ, G. *České pivo*. Praha: Havlíček Brain Team, 2011. ISBN 978-80-87109-25-0.

BOROWIEC, P. – MÜLLEROVÁ, B. – TITZLOVÁ, M. *Kniha o pivu : jak pivo poznávat, ochutnávat a párovat s jídlem*. Praha: Smart Press, 2017. ISBN 978-80-87049-96-9.

CIPRA, T. *Finanční ekonometrie*. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.

HANČLOVÁ, J. *Ekonometrické modelování : klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. ISBN 978-80-7431-088-1.

HUŠEK, R. *Ekonometrická analýza*. Praha: Ekopress, 1999. ISBN 80-86119-19-.

HUŠEK, R. – PELIKÁN, J. *Aplikovaná ekonometrie : teorie a praxe*. Praha: Professional Publishing, 2003. ISBN 80-86419-29-0.

HUŠEK, R. – WALTER, J. *Ekonometrie*. PRAHA: SNTL, 1976.

TVRDOŇ, J. *Ekonometrie*. V Praze: Česká zemědělská univerzita, Provozně ekonomická fakulta, 1996. ISBN 80-213-0287-9.

Předběžný termín obhajoby

2019/20 LS – PEF

Vedoucí práce

Ing. Olga Regnerová, Ph.D.

Garantující pracoviště

Katedra obchodu a financí

Konzultant

Ing. Daniela Šálková, Ph.D.

Elektronicky schváleno dne 25. 2. 2020

prof. Ing. Luboš Smutka, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 26. 2. 2020

Ing. Martin Pelikán, Ph.D.

Děkan

V Praze dne 06. 04. 2020

Čestné prohlášení

Prohlašuji, že svou diplomovou práci "Vývoj spotřeby piva v České republice" jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu použitých zdrojů na konci práce. Jako autor uvedené diplomové práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušil autorská práva třetích osob.

V Praze dne 6.4.2020

Poděkování

Rád bych touto cestou poděkoval Ing. Olga Regnerová, Ph.D., za rady, doporučení a návrhy související s vypracováním mé diplomové práce.

Vývoj spotřeby piva v České republice

Abstrakt

Diplomová práce je rozdělena celkem na tři stěžejní části, a to část metodickou, teoretickou a část praktickou. V části metodiky jsou podrobněji popsány potřebné postupy pro konstrukci ekonometrického modelu a následně prognóza ekonometrického modelu na následující období.

V teoretické části jsou zpracovány základní poznatky o pivu a jeho spotřebě v České republice. Je zde také vysvětlen pojem samotné ekonometrie a ekonometrického modelu jako takového. V teoretické části jsou dále rozebrány druhy proměnných využívaných v ekonometrických modelech a tzv. AR modely. Část praktická se zabývá samotnou konstrukcí jednorovnicového ekonometrického modelu na spotřebu piva a je zde dále vytvořena prognóza na následující období.

Klíčová slova: ekonometrie, ekonometrický model, analýza, pivo, spotřeba, vývoj, cena

Development of beer consumption in the Czech Republic

Abstract

This diploma thesis is divided into three main parts; the methodical part, the theoretical part and the practical part. The part of the methodology describes in detail the necessary procedures for the construction of the econometric model and then the forecast of the econometric model for the next period.

The theoretical part consists of basic information about beer itself as well as beer consumption in the Czech Republic. There is also an explanation of the concept of econometrics and the econometric model itself, along with types of variables that are used in econometric models and concept of autocorrelation model. The practical part deals with the construction of a single equation econometric model for beer consumption and there is a forecast created for the next three years.

Keywords: econometrics, econometric model, analysis, beer, consumption, development, price

Obsah

1 Úvod.....	11
2 Cíl práce.....	12
3 Metodika	13
3.1 Fáze konstrukce ekonometrického modelu.....	14
3.1.1 Ekonomická teorie	14
3.1.2 Tvorba ekonomického modelu	14
3.1.3 Tvorba ekonometrického modelu	14
3.1.4 Sběr, zpracování a analýza vstupních dat	16
3.1.5 Odhad parametrů ekonometrického modelu.....	17
3.1.6 Ekonomické ověření modelu	19
3.1.7 Statistické a ekonometrické ověření	20
4 Teoretická východiska	34
4.1 Pivo	34
4.2 Spotřeba piva.....	34
4.3 Ekonometrie	44
4.4 Ekonomická teorie	44
4.5 Ekonometrický model	46
4.6 Druhy proměnných v ekonometrickém modelu.....	48
4.7 AR modely	49
5 Vlastní práce	50
5.1 Ekonomická teorie	50
5.1.1 Výběr a popis proměnných.....	50
5.2 Tvorba ekonomického a ekonometrického modelu	51
5.3 Sběr dat.....	52
5.3.1 Datová tabulka	52
5.3.2 Vývoj proměnných v čase.....	53
5.3.3 Deskriptivní statistiky	60
5.3.4 Korelační matice	61
5.4 Odhad parametrů ekonometrického modelu	61
5.5 Statistické a ekonometrické ověření.....	62
5.5.1 Ekonometrické ověření - Test multikolinearity	62
5.5.2 Ekonometrické ověření – Testování autokorelace.....	63
5.5.3 Ekonometrické ověření – Test normality.....	63
5.5.4 Ekonometrické ověření – Test heteroskedasticity	64
5.5.5 Ekonometrické ověření – Test nelinearity	65

5.5.6	Statistické ověření – Testování významnosti odhadnutých parametrů.....	67
5.5.7	Statistické ověření – Shoda modelu s daty	67
5.5.8	Testování nové hypotézy	67
5.6	Ekonomické ověření modelu.....	68
5.7	Aplikace ekonometrického modelu.....	68
5.7.1	Pružnosti (elasticita)	68
5.8	Nelineární model.....	70
5.8.1	Prognózy	75
Závěr		85
6 Seznam použitých zdrojů		87
7 Přílohy		91

Seznam obrázků

Obrázek 1: Spotřeba piva na jednoho obyvatele za rok v litrech	35
Obrázek 2: Pivo ve společnosti.....	36
Obrázek 3: Hospodářské výsledky pivovarského oboru 2018.....	43
Obrázek 4: Výstup 2. odhadu	62
Obrázek 5: Test multikolinearity – VIF.....	62
Obrázek 6: Test autokorelace	63
Obrázek 7: Test normality	63
Obrázek 8: Test heteroskedasticity	64
Obrázek 9: Test heteroskedasticity kontrolní	65
Obrázek 10: Test nelinearity	66
Obrázek 11: Test nelinearity podrobný	66
Obrázek 12: Testování významnosti parametrů	67
Obrázek 13: Výstup 3. odhadu	70
Obrázek 14: Test autokorelace nelineární model	71
Obrázek 15: Test normality nelineární model	71
Obrázek 16: Test heteroskedasticity nelineární model	72
Obrázek 17: Testování významnosti parametrů nelineární model	74
Obrázek 18: Odhad modelu pro ověření kvality prognózy.....	76
Obrázek 19: prognózované hodnoty ex-post prognózy	77
Obrázek 20: Autoregresní model pro SpC_P	79
Obrázek 21: Prognózované hodnoty SpC_P.....	79
Obrázek 22: Autoregresní model produkce piva	81
Obrázek 23: Prognózované hodnoty produkce piva	81
Obrázek 24: Autoregresní model pro Mn	82
Obrázek 25: Prognózované hodnoty Mn	82
Obrázek 26: Odhad modelu pro ex-ante prognózu spotřeby piva	83
Obrázek 27: Prognózované hodnoty spotřeby piva	84
Obrázek 28: Celková spotřeba piva za rok v litrech.....	II
Obrázek 29: Cena piva v jednotlivých zemích	III
Obrázek 30: Výstup autoregresního modelu SpC_P 1	V
Obrázek 31: Výstup autoregresního modelu SpC_P 2	V

Obrázek 32: Výstup autoregresního modelu SpC_P 3	VI
Obrázek 33: Výstup autoregresního modelu SpC_4 1	VI
Obrázek 34: Výstup autoregresního modelu Pr_P 1	VII
Obrázek 35: Výstup autoregresního modelu Pr_P 2	VII
Obrázek 36: Výstup autoregresního modelu Pr_P 3	VIII
Obrázek 37: Výstup autoregresního modelu Pr_P 4	VIII
Obrázek 38: Výstup autoregresního modelu Mn 1	IX
Obrázek 39: Výstup autoregresního modelu Mn 2	IX
Obrázek 40: Výstup autoregresního modelu Mn 3	X

Seznam grafů

Graf 1: Podíly konzumentů piva mezi muži a ženami	38
Graf 2: Týdenní konzumace piva	39
Graf 3: Frekvence konzumace piva	40
Graf 4: Postoj ke spotřebě piva muži	41
Graf 5: Postoj ke spotřebě piva ženy	41
Graf 6: Vývoj spotřeby piva	53
Graf 7: Postkrizový zlom ve spotřebě piva	54
Graf 8: Vývoj spotřebitelské ceny piva	54
Graf 9: Vývoj produkce piva	55
Graf 10: Vývoj míry nezaměstnanosti	56
Graf 11: Vývoj míry inflace	57
Graf 12: Vývoj platební bilance	58
Graf 13: Vývoj průměrné mzdy	59
Graf 14: Vývoj spotřebitelské ceny vína	60
Graf 15: Graf test normality	64
Graf 16: Graf reziduí	65
Graf 17: Pružnosti v jednotlivých letech	69
Graf 18: Graf test normality nelineární model	72
Graf 19: Graf reziduí nelineární model	73
Graf 20: Hranice produkce piva	74
Graf 21: ex-post prognóza spotřeby piva	77
Graf 22: Prognóza spotřebitelské ceny piva	79
Graf 23: Prognóza produkce piva	80
Graf 24: Prognóza obecné míry nezaměstnanosti	82
Graf 25: ex-ante prognóza spotřeby piva	84

Seznam tabulek

Tabulka 1: Deskriptivní statistiky	60
Tabulka 2: Korelační matice	61
Tabulka 3: Výpočet pružností	68
Tabulka 4: Datová tabulka	I

1 Úvod

Pivo je celosvětově nejrozšířenějším alkoholickým nápojem, a především v České republice, kde se vyrobí nejvíce piva v přepočtu na jednoho obyvatele z celé Evropy, se těší velké oblibě. Není tak proto překvapením, že Česká republika drží prvenství ve spotřebě piva na jednoho obyvatele z celé Evropské unie. V roce 2018 dosáhla dle údajů Českého statistického úřadu dokonce spotřeba piva 145,19 litrů na jednoho obyvatele za rok. Dokonce se říká, že Češi jsou největšími konzumenty piva na světě.

Jednou z největších příčin tak vysoké poptávky po pivu, je kromě výborné chuti českého piva, za kterou vděčíme především třem největším tuzemským producentům piva, kterými jsou Plzeňský Prazdroj, Pivovary Staropramen a Heineken Česká republika, jistě i jeho cena.

Podle průzkumů je v České republice pivo z celého světa dokonce nejlevnější. Jeho spotřebu však ovlivňují i další faktory, a právě tyto možné faktory, které mohou spotřebu piva v České republice ovlivňovat, budou na základě provedení kvantitativní analýzy tuzemské spotřeby piva, v této diplomové práci rozebrány. Na základě provedení této analýzy bude následně vytvořena prognóza spotřeby piva v České republice na následující 3 období, respektive roky.

2 Cíl práce

Hlavním cílem této diplomové práce je provedení kvantitativní analýzy tuzemské spotřeby piva a dále provedení prognózy spotřeby piva v České republice pro následující období.

Mezi dílčí cíle práce patří:

- a) definování determinantů, které mohou mít vliv na vývoji spotřeby
- b) odhad a verifikace ekonometrického modelu
- c) testování nové hypotézy ohledně vlivu míry nezaměstnanosti na spotřebu piva
- d) strukturální analýza determinantů působících na spotřebu piva
- e) verifikace prognostických schopností

3 Metodika

Průběh zpracování je následující: nejprve je potřeba nalézt vysvětlující proměnné, což bude provedeno na základě studia dokumentů. Po nalezení a určení vysvětlujících proměnných bude na základě odvození z ekonomické teorie zformulován ekonomický model. Poté bude určením funkční formy modelu a přidáním náhodné složky zformulován model ekonometrický. Poté následuje sběr dat, přičemž proměnné budou mít roční periodicitu, a to v období let 1994-2018. Data budou získávána především z Českého statistického úřadu (ČSÚ). Odhad parametrů bude prováděn pomocí běžné metody nejmenších čtverců (dále BMNČ) v softwaru Gretl a některé početní operace při tvorbě této diplomové práce budou taktéž prováděny v programu MS Excel. Odhadnutý ekonometrický model je nutné před jeho aplikací nejprve ověřit nebo tzv. verifikovat. Pro ověření a vyhodnocení, bude provedeno ekonomické, statistické a ekonometrické ověření modelu. Nejprve bude provedeno ověření ekonometrické, protože ekonometrické ověření zahrnuje testování multikolinearity, autokorelace, heteroskedasticity a normality reziduí. Případná autokorelace reziduí totiž zhoršuje výsledky statistické verifikace, a tak se musí provádět dopředu. Případná přítomnost heteroskedasticity v modelu zapříčiňuje výsledky statistické verifikace nedůvěryhodnými. Po ekonometrickém ověření bude provedeno ověření statistické, protože v případě statistické nevýznamnosti parametrů v modelu, by nemělo ani smysl model ekonomicky ověřovat. Následuje tedy ekonomické ověření, kde se posuzuje směr a intenzita vzájemného působení zahrnutých proměnných v modelu. Konečnou implementační fází je aplikace ekonometrického modelu, tedy jeho praktické využití pro účely analýzy či pro prognózování. Bude provedena jak prognóza ex-post, tak prognóza ex-ante. Pro ověření kvality prognózy poskytované výsledným modelem byla provedena ex-post prognóza na 3 poslední období, tedy na roky 2016-2018. Pro zajištění ex-post prognózy na tato období byly časové řady zkráceny o 3 poslední období, na základě této zkrácené datové základny byly odhadnuty parametry stejného modelu. Prognóza ex-ante bude stanovena na 3 následující období. Pro stanovení ex-ante prognózy bylo potřeba do ekonometrického modelu dosadit odhady budoucích hodnot vysvětlujících proměnných v letech 2019-2021 pomocí autoregresních modelů. Poté mohla být stanovena prognóza ex-ante vysvětlované proměnné na 3 následující období. Prognózy jsou vyjádřeny graficky v SW Gretl a také slovně okomentovány.

3.1 Fáze konstrukce ekonometrického modelu

3.1.1 Ekonomická teorie

Ekonomická teorie, tedy první fáze konstrukce ekonometrického modelu, je zpracována v literární rešerši, kapitole 4.5 a praktické části, kapitole 5.1

3.1.2 Tvorba ekonomického modelu

Ekonomický model, který je odvozen z ekonomické teorie, je zjednodušenou abstrakcí reálného světa. Ekonomický model je formulací základních hypotéz. Lze dospět k více než jedné základní hypotéze, a to v závislosti na výchozích předpokladech jednotlivých ekonomických teorií. Platí, že nejsme schopni předem s jistotou stanovit, která ze stanovených hypotéz je správná. Vztahy mezi ekonomickými proměnnými v ekonomickém modelu mohou být zapsány buď slovně, graficky, anebo algebraicky. Pomocí ekonomického modelu je možná matematická a statistická formalizace verbálně popsaných teoretických předpokladů a poznatků. Provedením matematické specifikace a transformace ekonomického modelu, se jedná o adekvátní vyjádření základní hypotézy. Přestože jde o značné zjednodušení, jedná se o únosný stupeň zjednodušení. Výsledkem je pak deterministický ekonomicko-matematický model. (Hušek, 2007)

3.1.3 Tvorba ekonometrického modelu

Z ekonomického modelu se stane model ekonometrický určením funkční formy modelu a přidáním náhodné složky (náhodné proměnné), díky které je respektována stochastická povaha modelovaného vztahu. (Hušek 2007)

Podle Huška (2007) spočívá specifikace ekonometrického modelu v následujících krocích:

- a) Určením a klasifikací všech proměnných zahrnutých do modelu korespondující s apriorní i výběrovou informací získanou z ekonomické teorie a dat
- b) Stanovením předpokládaných znamének (směru) a očekávaných hodnot (intenzity) odhadnutých parametrů modelu

Znaménka neboli směr jednotlivých parametrů, se určují na základě ekonomické teorie, nebo jsou k tomu využívány informace z jiných kvantitativních studií a analýz.

- c) Volbou matematického a analytického tvaru modelu, popřípadě jeho jednotlivých rovnic

Platí, že se snažíme volit model v analytickém tvaru tak, aby byly závislosti vysvětlovaných, ale i vysvětlujících proměnných lineárního v parametrech. A to již v původní specifikaci modelu nebo v případě potřeby zlinearizování modelu jednoduchou transformací v průběhu. To platí například pro zlogaritmování.

Vzhledem ke skutečnosti, že se většina ekonomických veličin vyvíjí v čase, což znamená, že reakce na změny vyžadují určitý čas, je vhodné do modelu zahrnout faktor času. Tento proces, kdy se do modelu zahrne faktor času, se nazývá dynamizací modelu. Po zahrnutí faktoru času do modelu, se model svou povahou stává dynamickým. (Gujarati a Porter, 2009)

Podle Huška (1999) lze model dynamizovat následovně:

- zahrnutím zpožděných proměnných,
- vyjádřením proměnných v postupných diferencích nebo relativně,
- zahrnutím časového vektoru jako další proměnné,
- zahrnutím dummy proměnné.

Dummy proměnné jsou využívány v ekonometrických modelech pro zachycení efektů, které mění, respektive posouvají hodnotu vysvětlované proměnné za účelem dynamizace, například pro zachycení sezónnosti apod. Nabývají hodnot tzv. $[0,1]$ podoby. Přičemž hodnota 0 reprezentuje situace, kdy daný jev nenastává a hodnota 1 reprezentuje situace přítomnosti daného jevu.

Výsledný ekonometrický model znázorňuje závislost jedné vysvětlované proměnné na jedné či více vysvětlujících proměnných a také náhodné složce.

Jednorovnicový lineární ekonometrický tvar ekonometrického modelu může mít následující tvar:

$$y_{1t} = \gamma x_{1t} + \gamma x_{2t} + \gamma x_{3t} + \gamma x_{4t} + u_{1t} \quad (3.1)$$

kde: y_{1t} znázorňuje vysvětlovanou endogenní proměnnou

$x_{1t}, x_{2t}, x_{3t}, x_{4t}$ znázorňují vysvětlující proměnné

γ jsou parametry vysvětlujících proměnných

u_{1t} je náhodná složka

3.1.4 Sběr, zpracování a analýza vstupních dat

Ve čtvrté fázi se shromažďují vstupní data endogenních a predeterminovaných proměnných v daném modelu. Ekonometrie se zabývá třemi typy statistických dat a těmi jsou časové řady, průřezová data a panelová data.

Údaje časových řad nám poskytují informace o numerických neboli číselných hodnotách proměnných v jednotlivých po sobě jdoucích obdobích, která mají různou délku. Nejčastěji se jedná o roční data a dále o data čtvrtletní, měsíční či data denní. (Hušek, 2007) Taková data se značí časovým indexem „t“. (Cipra, 2008)

Hušek (2007) uvádí, že u údajů časových řad je nezbytně nutné provést doplnění chybějících pozorování a očištění od sezónnosti, trendu, cyklických či konjunkturních vlivů extrapolací, interpolací nebo vyrovnáním, a to ještě před jejich použitím k odhadu.

Průřezová data představují pozorování proměnných ve stejném období, která se týkají jednotlivých subjektů. To znamená, že data jsou k určitému okamžiku. Průřezová data mají charakter prostorových údajů v případě, že shrnují informace za různé regiony nebo země právě v daném období. Příkladem může být sledování spotřeby určité komodity v tuzemských regionech za určitý rok. Kombinování údajů z časových řad a průřezová data bývá v některých zkoumáních velmi užitečné. Platí to například v případě tzv. smíšeného odhadu koeficientů pružnosti poptávky po určité komoditě. Uvedená kombinace tak často vnáší do modelu více informací.

Posledním typem jsou panelová data, která jsou zvláštním druhem statistických údajů. Vznikají opakováním výběrového šetření s daným programem u stejné skupiny respondentů v různých obdobích. Příkladem panelových dat mohou být údaje o příjmech určité skupiny lidí zjišťované opakovaně například několik po sobě jdoucích měsíců či let. (Hušek, 2007)

3.1.5 Odhad parametrů ekonometrického modelu

Pro odhad parametrů ekonometrického modelu je nejprve nutné si zvolit a také aplikovat odpovídající odhadový postup. Odhad parametrů jednoduchého ekonometrického modelu, respektive kvantifikace neznámých parametrů se provádí pomocí klasického lineárního regresního modelu. Nejznámějším postupem pro odhad lineárního regresního modelu je metoda nejmenších čtverců (Fiala, 2008).

Pro jednorovnicový ekonometrický model, který má funkční závislost lineární nebo nelineární, ale je možné jej matematickým postupem zlinearizovat, se používá běžná metoda nejmenších čtverců (BMNČ). U víceroznicových a simultánních modelů se používají buď metody s omezenou informací, nebo metody s úplnou informací. U metod s omezenou informací se odhadují parametry každé rovnice zvlášť. Mezi metody s omezenou informací patří právě BMNČ, dále dvoustupňová metoda nejmenších čtverců (DMNČ) a metoda minimalizace poměru rozptylů (MMPR). U metod s úplnou informací se odhadují parametry všech rovnic ekonometrického modelu najednou. (Tvrdoň, 2014).

Podle Cipry (2013) podávají odhadnuté parametry ekonometrického modelu nestranné, eficientní (výkonné či účinné) a zároveň konzistentní odhady označované jako BLUE (best = nejlepší, linear = lineární, unbiased = nestranné a estimation = odhady). Tyto odhady parametrů jsou získány za určitých podmínek dodržení specifikačních předpokladů daného modelu a dodržení předpokladů o náhodné složce neboli stochastické předpoklady, které jsou uvedeny níže.

Specifikační předpoklady:

- a) Zahrnutí relevantních proměnných,
- b) Vypuštění irelevantních vysvětlujících proměnných,

- c) Volba správného funkčního tvaru,
- d) Časová invariantnost – odhadnuté parametry by měli být v čase stabilní,
- e) Respektování simultánnosti vazby.

Stochastické předpoklady - předpoklady o náhodné složce:

- a) Nulový průměr náhodné složky – střední hodnota náhodné proměnné by se měla rovnat, respektive blížit nule ($E(u_t) = 0$)
- b) Rozptyl reziduální složky je konstantní a konečný tzv. homoskedasticita reziduí ($var(u_t) = \sigma^2 < \infty$)
- c) Nepřítomnost autokorelace reziduí – nezávislost náhodné proměnné na svých vlastních zpožděných proměnných
- d) Nezávislé proměnné musí být nenáhodné a fixní – v opakujících se souborech
- e) Neexistence perfektní multikolinearity
- f) Normální rozdělení náhodné složky

V této diplomové práci je odhadován jednorovnicový ekonometrický model. Model je odhadován pomocí metody BMNČ v SW Gretl.

Klein (1966) definuje běžnou metodu nejmenších čtverců (BMNČ) jako metodu, která poskytne k vytvářenému jednorovnicovému modelu hodnoty koeficientů, které minimalizují součet čtverců reziduálních odchylek. Podle Huška (2007) se zpravidla se postupuje tak, že původní (neboli výchozí) varianta modelu se specifikuje v co nejjednodušší formě a poté se na základě výsledků provedeného testování model modifikuje a zdokonaluje.

Kritériem metod nejmenších čtverců je minimalizace součtu čtverců odchylek teoretických hodnot vysvětlované proměnné od jejich hodnot skutečných. Jednodušeji řečeno, metoda minimalizuje čtverce reziduí. Podstatou BMNČ je tedy zalezení takových parametrů, které co nejvíce minimalizují součet čtverců odchylek teoretických hodnot vysvětlované proměnné od jejich skutečných hodnot. (Tvrdoň, 2010)

$$\min \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.2)$$

Kritérium metody nejmenších čtverců lze vyjádřit i v maticové podobě a to následovně:

$$\gamma = (X^T X)^{-1} \times X^T \times y \quad (3.3)$$

kde: γ je vektor odhadovaných parametrů o rozměru $k \times 1$

X je matice napozorovaných hodnot vysvětlujících proměnných o rozměru $n \times k$

y je vektor napozorovaných hodnot vysvětlované proměnné o rozměru $n \times 1$

3.1.6 Ekonomické ověření modelu

Ekonomické ověření je nezbytnou podmínkou pro základní zhodnocení a primární vyhodnocení odhadnutého modelu z hlediska ekonomické teorie.

Ekonomické ověření modelu spočívá v ověření správnosti znamének a velikosti číselných hodnot odhadovaných parametrů daného modelu. Znaménka reprezentující směr z pohledu vysvětlujících proměnných působících na proměnnou vysvětlovanou. Velikost číselných hodnot reprezentuje intenzitu. Intenzita je posuzována s přihlédnutím k reálně možné či předpokládané síle působení. V případě, že jsou očekávané odhady v souladu s předpokládanými znaménky neboli směru a hodnot jednotlivých parametrů, je možné je interpretovat ve shodě s teoretickými ekonomickými předpoklady, tedy jsou konzistentní se stanovenou ekonomickou teorií a odhadnutý ekonometrický model je adekvátním. V případě, že znaménka nebo hodnoty odhadnutých parametrů neodpovídají výchozím ekonomickým předpokladům, je nutné model nebo jednotlivé rovnice specifikovat odlišným způsobem, případně přezkoumat ekonomickou teorii (Hušek, 2007).

Součástí ekonomického ověření je interpretace odhadnutých parametrů, které říká o kolik se při jednotkové změně vysvětlované proměnné změnila proměnná vysvětlující, za

podmínek *ceteris paribus* neboli za předpokladu, že jsou ostatní proměnné konstantní. Ekonomické ověření se provádí ke každému parametru zvlášť. (Wooldridge, 2008)

3.1.7 Statistické a ekonometrické ověření

Statistické ověření

Statistické ověření slouží k posouzení statistické reálnosti jednotlivých odhadnutých parametrů v modelu i celého ekonometrického modelu. V rámci statistického ověřování je tedy ověřována významnost odhadnutých parametrů a významnost modelu jako celku. Ověřování je založeno na statistických testech, pomocí kterých se ověřuje přesnost nebo významnost výsledků kvantifikace získaných z jednoho výběru pozorování. (Hušek, 2007)

Hušek (2007) dále uvádí, že mezi nejčastější kritéria statistického ověřování se řadí standartní chyby odhadnutých parametrů, dále koeficienty vícenásobné determinace a t-testy a F-testy statistické významnosti odhadnutých parametrů.

Koeficient vícenásobné determinace (R^2) vyjadřuje, z kolika procent jsou změny vysvětlované proměnné vysvětleny změnami vysvětlujících proměnných. Hodnota (R^2) se pohybuje od 0 % do 100 %, přičemž 100 % vyjadřuje, že daná funkce plně vystihuje zkoumaný vztah (všechna rezidua jsou tedy nulová). Protože však hodnota (R^2) zpravidla vždy roste přidáním další vysvětlující proměnné do modelu, používá se také tzv. korigovaný koeficient vícenásobné determinace, který penalizuje nadměrný počet regresorů. Tedy po přidání nesprávné proměnné, hodnota korigovaného koeficientu vícenásobné determinace naopak klesne.

Koeficient vícenásobné determinace je podle Gujarati (2004) vyjádřen vztahem:

$$R^2 = 1 - \frac{S_u^2}{S_y^2} \quad (3.4)$$

Kde; S_u^2 reziduální rozptyl

S_y^2 celkový rozptyl

Ukazatel je založen na rozkladu celkového rozptylu vysvětlované proměnné na rozptyl reziduální a teoretický.

Rozklad celkového rozptylu je vyjádřen vztahem:

$$S_y^2 = S_{\hat{y}}^2 + S_u^2 \quad (3.5)$$

Kde; $S_{\hat{y}}^2$ teoretický rozptyl

S_u^2 reziduální rozptyl

Teoretický rozptyl je vyjádřen vztahem:

$$S_{\hat{y}}^2 = \frac{\sum_{t=1}^n (\hat{y}_t - \bar{y})^2}{n} \quad (3.6)$$

Kde; \hat{y}_t teoretické hodnoty vysvětlované proměnné v jednotlivých letech pozorování

\bar{y} průměr skutečných hodnot vysvětlované proměnné

n délka časové řady

Reziduální rozptyl je vyjádřen vztahem:

$$S_u^2 = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} \quad (3.7)$$

Kde; y_t skutečné hodnoty vysvětlované proměnné v jednotlivých letech pozorování

Výsledný celkový rozptyl je zároveň vyjádřen vztahem:

$$S_y^2 = \frac{\sum_{t=1}^n (y_t - \bar{y})^2}{n} \quad (3.8)$$

Korigovaný koeficient vícenásobné determinace je vyjádřen vztahem (Cipra, 2013):

$$\overline{R^2} = 1 - (1 - R^2) \frac{n-1}{n-p} \quad (3.9)$$

Kde; p počet odhadovaných parametrů v dané rovnici

$n - p$ počet stupňů volnosti)

Ověřování významnosti strukturálních parametrů je založeno na principu testování hypotéz, které vycházejí ze statistické teorie. Postup testování hypotéz je následující:

1. stanovení nulové a alternativní hypotézy (H_0 a H_1)
2. výpočet testové statistiky
3. rozhodovací pravidlo o přijetí či zamítnutí nulové hypotézy pro stanovenou hladinu významnosti

V prvním bodě je tedy nutné stanovit hypotézu nulovou hypotézu a hypotézu alternativní. Nulová hypotéza je definována takto: (3.10)

$$H_0: \gamma = 0$$

$$H_1: \gamma \neq 0$$

Nulová hypotéza říká, že daný parametr se rovná nule. To znamená, že není statisticky významný, respektive že daná vysvětlující proměnná tohoto parametru nepřispívá k vysvětlení změn variability vysvětlované proměnné. Alternativní hypotéza říká, že parametr se nerovná nule (je různý od nuly), a proto proměnná tohoto parametru přispívá k vysvětlení variability vysvětlované proměnné. (Cipra, 2013)

T-test, stejně jako interval spolehlivosti nebo p-hodnota, testuje významnost odhadnutých parametrů v modelu. Výpočet t-testu bývá prováděn v šesti následujících krocích:

Nejprve je potřeba vypočítat matici pro ověření statistické významnosti parametrů:

$$(X^T X)^{-1} \quad (3.11)$$

Následně je proveden výpočet korigovaného reziduálního rozptylu:

$$\overline{S_u^2} = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n-p} \quad (3.12)$$

Poté přichází na řadu výpočet rozptylu odhadnutých parametrů:

$$S_{ii} = \overline{S_u^2} (X^T X)^{-1} = \begin{pmatrix} S_{11} & \cdots & S_{ii} \\ \vdots & \ddots & \vdots \\ S_{ii} & \cdots & S_{ii} \end{pmatrix} \quad (3.13)$$

kde prvky na hlavní diagonále znázorňují rozptyly odhadnutých parametrů.

Ve třetím kroku přichází na řadu výpočet standardní chyby odhadnutých parametrů z

$$\text{odmocnin prvků z hlavní diagonály výše uvedené matice: } S_{bi} = \sqrt{S_{ii}} \quad (3.14)$$

V předposledním kroku je potřeba vypočítat testovací kritérium: $t - \text{hodnota} =$

$$\frac{\text{hodnota parametru}}{\text{chyba parametru}} = \frac{|y_{it}|}{S_{bi}} \quad (3.15)$$

V posledním, šestém kroku, je porovnávána vypočtená t-hodnota s tabulkovou hodnotou t-testu na zvolené hladině významnosti, a to s přihlédnutím k příslušnému počtu stupňů volnosti $t\alpha$. Pokud je $t > t\alpha$, zamítá se nulová hypotéza o statistické nevýznamnosti parametrů. Vysvětlující proměnná je tedy významnou proměnou na dané hladině významnosti α . (Gujarati, 2004; Cipra, 2013)

Koeficient vícenásobné determinace a statistická významnost parametrů v modelu je spolu se statistickou významností celého modelu, vypočtena v této diplomové práci pomocí SW Gretl. Statistická významnost je v SW Gretl určována dle tzv. p-hodnoty. Podle Cipry (2013) vyjadřuje p-hodnota maximální hladinu významnosti, při které není ještě nulová hypotéza zamítnuta. Jinak řečeno, je to minimální hladina významnosti, při které by se ještě tato nulová hypotéza zamítla. P-hodnota by měla tedy být co nejnižší. Pro hladinu významnosti $\alpha = 0,05$ platí, že parametr bude významný, pokud p-hodnota bude menší než uvedená hladina významnosti. Jinak řečeno, pokud bude p-hodnota menší než hladina významnosti $\alpha = 0,05$, zamítáme nulovou hypotézu o statistické nevýznamnosti parametru a tento parametr je tedy významný na hladině spolehlivosti 95 %.

Ekonometrické ověření

V ekonometrickém ověřování se provádí ověření stochastických předpokladů, tedy předpokladů o náhodné složce. Vzhledem ke skutečnosti, že splnění ekonometrických předpokladů je podmínkou pro statistické ověřování a pro možnou aplikaci ekonometrického modelu k prognózám, mělo by se ekonometrické ověřování provádět před tím. V části ekonometrického ověřování bude proveden test na výskyt multikolinearity, testování přítomnosti autokorelace, test normality náhodné složky a test heteroskedasticity.

Multikolinearita

Multikolinearita představuje těsnosti závislosti mezi dvěma či více vysvětlujícími proměnnými v rovnici. Cipra (2013) uvádí, že ze statistického hlediska, není multikolinearita nic jiného než vysoká vzájemná korelovanost daných regresorů. Multikolinearita je nežádoucím jevem, a to především proto, že v takovém případě nelze separovat vliv vysoce zkorelovaných proměnných, tedy by nebylo možné vymezit jednotlivé vlivy vysvětlujících proměnných na proměnné vysvětlované. Nejčastěji se multikolinearita v modelu objevuje v případě, když mají dané proměnné stejnou trendovou tendenci, je tomu tak především u dat makroekonomických ukazatelů.

Zjištění multikolinearity se provádí pomocí párové korelační matice. Vysoká korelace je měřena pomocí korelačního koeficientu. Rozlišujeme perfektní a vysokou korelaci, tedy těsnost závislosti. Pokud korelační koeficient dosahuje hodnoty alespoň 0,8 (v absolutní hodnotě), jedná se o vysokou korelaci. Pokud dosahuje hodnoty 1 (v absolutní hodnotě), jedná se o lineární závislost a tzv. perfektní korelaci. V případě, že se v modelu perfektní korelace vyskytuje, má párová korelační matice determinant blízký nule a matici proto nelze invertovat. Odhad strukturálních parametrů metodou nejmenších čtverců by tak nebyl možný. (Cipra, 2008)

Ke zjištění multikolinearity lze taktéž použít test VIF (The variance inflation factor). Jedná se o metodu, která detekuje závažnost lineární závislosti vysvětlujících proměnných. Vysoká hodnota VIF zvyšuje odchylku odhadu. Hodnota vyšší, než deset znamená vysokou korelaci a obvykle signalizuje multikolinearitu mezi vysvětlujícími proměnnými. (Studenmund, 2014).

Vzorec je následující: $VIF = \frac{1}{1-R_i^2}$ (3.16)

Kde; R_i^2 koeficient vícenásobné determinace dané proměnné (např. x_1 apod.)

Příčiny a důsledky multikolinearity podle Hančlové (2012):

Mezi příčiny multikolinearity patří:

- stejný trend ekonomických časových řad
- neexperimentální charakter disponibilních dat (zejména při průřezové analýze)
- nevhodně zavedené zpožděné vysvětlující proměnné
- neadekvátní použití umělých proměnných

Mezi důsledky multikolinearity patří:

- nelze separovat vliv jednotlivých vysvětlujících proměnných na vysvětlovanou proměnnou
- odhadnuté parametry jsou nezkreslené a vydatné
- odhady parametrů modelu mají velký rozptyl
- odhady parametrů a jejich rozptyly jsou velmi citlivé na malé změny ve výběrových datech a specifikaci modelu

Způsoby odstranění multikolinearity uvádí Cipra (2008) následující:

- Vyřazení proměnné způsobující multikolinearitu z modelu
- Ignorování multikolinearity v případě statistické významnosti parametrů
- Nahrazení proměnné způsobující multikolinearitu:
 - a) Postupnými diferencemi (1. diferencemi)
 - b) Relativními odchylkami

- c) Normovanými odchylkami
- d) Přidáním dummy proměnné
- Rozšíření časové řady

Autokorelace reziduí

Autokorelace reziduální složky vyjadřuje závislost náhodné složky na svých vlastních zpožděných hodnotách, případně budoucích hodnotách. Hušek (2007) říká, že autokorelací je „závislost nikoli mezi dvěma nebo několika proměnnými, nýbrž mezi posloupností hodnot jedné proměnné, uspořádaných v čase, někdy i v prostou.“ V případě odhadu modelu s autokorelací reziduální složky je model sice nestranný a konzistentní, ale není nejlepší. Přítomnost autokorelace je možné ověřit prostřednictvím grafických analýz a analytických testů.

Příčiny a důsledky autokorelace podle Huška (2007):


- Značná setrvačnost ve vývoji (tudíž nejsou jejich pozorování za několik po sobě jdoucích období nezávislé, ale sériově zkorelovaná)
- Nepřesná či chybná specifikace analytické formy modelu
- Zahrnutí chyb měření vysvětlované proměnné do náhodné složky modelu
- Nesprávně nastavené zpoždění u vysvětlujících proměnných
- Odhad modelu z dat, které obsahují zprůměrované, vyrovnané, interpolované či extrapolované údaje

Často bývá použit Durbin-Watsonův test, který testuje korelace pouze 1. řádu. U tohoto testu je opět stanovena nulová a alternativní hypotéza. H_0 vyjadřuje nepřítomnost autokorelace reziduí 1. řádu. H_1 vyjadřuje, že autokorelace 1. řádu je přítomna, což by znamenalo výskyt vzájemné závislosti mezi rezidui v čase.

Vztah Durbin-Watsonova (DW) testu je následující:

$$DW = d = \frac{\sum_{t=2}^n (u_t - u_{(t-1)})^2}{\sum_{t=1}^n u_t^2} \quad (3.17)$$

U DW testu je potřeba se řídit podle osy s nestandardním d-rozdělením v intervalu $< 0,4 >$ viz. Obrázek níže. K tomu je potřeba získat kritické hodnoty d_L a d_U , které najdeme v tabulkách podle počtu pozorování (n) a počtu vysvětlujících proměnných ($k - 1$).



Zdroj: vlastní zpracování, 2019

Platí, že v případě výsledku testu hodnoty $DW < d_L$ nebo hodnoty $DW > 4 - d_L$, se zamítá se nulová hypotéza na hladině významnosti α . Jinak řečeno, v modelu se vyskytuje pozitivní nebo negativní autokorelace reziduí 1. řádu. Když je výsledná hodnota DW testu v intervalu $< d_L, d_U >$ nebo $< 4 - d_U, 4 - d_L >$, jedná se o tzv. šedou zónu, kdy nelze rozhodnout, protože je test neprůkazný. V takovém případě je vhodné použít jiný test. V případě, že je výsledná hodnota DW testu v intervalu $< d_U, 4 - d_U >$, nulová hypotéza se na hladině významnosti α nezamítá a autokorelace reziduí 1. řádu se tak v modelu nevyskytuje. (Hančlová, 2012; Hušek a Walter, 1976)

Autokorelace reziduí je v této diplomové práci testována Breusch-Godfreyův testem pomocí SW Gretl. Pro testování autokorelace jsou stanoveny následující hypotézy: (3.18)

H_0 : Nepřítomnost autokorelace reziduí 1. řádu

H_1 : Přítomnost autokorelace reziduí 1. řádu

Vyhodnocení testu je provedeno na základě p-hodnoty. V případě, že je p-hodnota větší než zvolená hladina významnosti α , nelze nulovou hypotézu zamítnout a v modelu tedy není přítomna autokorelace reziduí

Normalita reziduí

Normální rozdělení patří mezi rozdělení, která jsou spojitá a symetrická. Toto rozdělení definují dva parametry, střední hodnota μ a rozptyl σ^2 . Platí, že reziduální složky jsou normálně rozdělené pro všechna t při konstantním rozptylu a nulové střední hodnotě. Tedy náhodná složka by správně měla mít normální rozdělení s nulovou střední hodnotou. V případě, dojde-li ke splnění předpokladu normality reziduí, jsou odhady koeficientů regrese BUE (best unbiased estimator), tedy tzv. nejlepší a nezaujatý odhad. Normalita je základním předpokladem pro statistické testování hypotéz, dále pro konstrukci intervalů spolehlivosti a také k nalezení maximálně věrohodných odhadů parametrů. Normalita je také zásadní podmínkou pro použití t-testů a F-testu. Normalitu reziduí lze statisticky testovat pomocí grafických nástrojů a neparametrických testů. Grafické testy bývají prováděny pomocí histogramu rozdělení četností reziduí, které jsou porovnávány s Gaussovou teoretickou křivkou. Testů normality je několik. Mezi nejznámější patří Jarque-Bera test, (Gujarati a Porter, 2009).

V této diplomové práci je pro ověření normality, tedy normálního rozdělení reziduí odhadovaného modelu, využit test normality v SW Gretl. Nulová hypotéza vyjadřuje skutečnost, že rezidua mají normální rozdělení a alternativní hypotéza tuto skutečnost vyvrací. V případě, je-li p-hodnota vyšší než hladina významnosti α , nelze zamítnout nulovou hypotézu a bude tak platit, že rezidua tak mají normální rozdělení.

Heteroskedasticita

Heteroskedasticita reprezentuje situaci, kdy je porušen jeden z předpokladů lineárního regresního modelu. Baltagi (2008) uvádí, že v modelu předpokládáme konstantní a konečný rozptyl reziduí, respektive náhodné složky (rezidua nazývá také náhodnou složkou pouze za předpokladu, že se v modelu nevyskytuje autokorelace reziduí), tedy v modelu předpokládáme Homoskedasticitu reziduí. Ta je opakem heteroskedasticity reziduí, která je tedy nežádoucím jevem, a proto se musí vždy v modelu testovat. Jinak řečeno, heteroskedasticita je situace, kdy je porušen požadavek konstantního a konečného rozptylu reziduí.

Předpoklad homoskedasticity tedy říká, rozptyl náhodných složek se pro daný odhadnutý model v čase nemění, jinak řečeno homoskedasticita znamená

stejnorozptylovost. Heteroskedasticita naopak vyjadřuje situaci, kdy se rozptyl náhodné složky mění, tedy znamená různorozptylovost, což je jev nežádoucí. (Hušek, 2007)

Mezi příčiny heteroskedasticity patří dle Krkoškové a kol. (2010):

- chybná specifikace regresního modelu (např. chybná funkční forma)
- odlehlá pozorování
- chyby v měření dat
- nevhodná transformace dat

Hušek (2007) uvádí, že heteroskedasticita způsobuje, že odhady regresních i stochastických parametrů, které jsou získané klasickou metodou nejmenších čtverců, ztrácejí některé optimální vlastnosti. Dále uvádí: „...i přes nedodržení požadavku konstantního a konečného rozptylu poskytuje MNČ nestranné a konzistentní bodové odhady regresních parametrů, které však ztrácejí vydatnost...“, nebudou tedy již nejlepšími. V případě homoskedasticity nejsou běžné testy statistické významnosti ani intervalový odhad použitelné, protože odhady rozptylů a standardních chyb odhadnutých regresních parametrů není možné získat pomocí vzorců odvozených právě v případě homoskedasticity. Výsledky testů jsou v takovém případě nereálné. Pro testování přítomnosti heteroskedasticity, lze využít několik testů. Hušek (2007) říká ke zjišťování a ověřování heteroskedasticity: „Protože heteroskedasticita je vlastností náhodných složek, které však neznáme, vycházejí metody testování heteroskedasticity ze známých hodnot reziduí, získaných při odhadu modelu klasickou MNČ“.

Pro testování heteroskedasticity je v této diplomové práci využit parametrický Whitův test v SW Gretl. Nulová hypotéza nám říká, že je v modelu přítomna homoskedasticita reziduí. Alternativní hypotéza vyjadřuje přítomnost heteroskedasticity. V případě vyšší p-hodnoty v SW Gretl než je stanovená stanovená hladina významnosti α platí, že není možné zamítnout nulovou hypotézu, což znamená nepřítomnost heteroskedasticity v modelu.

Kromě výše zmíněných ověření, by se zároveň mělo vždy provádět ověření stacionarity časových řad. Při stacionaritě časových řad jsou její základní vlastnosti,

například její průměr a rozptyl, v čase neměnné. Na rozdíl od nestacionárních časových řad, u kterých se naopak tyto vlastnosti v průběhu času mění. Stacionární časové řady se obvykle dosahuje pomocí prvních diferencí. (Wooldridge, 2006).

Aplikace ekonometrického modelu

Po odhadu a ověření ekonometrického modelu se provádí aplikace modelu. Ve fázi aplikace modelu, budou nejprve vypočteny pružnosti pro posouzení změn variability vysvětlované proměnné, které jsou způsobeny změnami variability vysvětlujících proměnných, a následně bude provedena prognóza vysvětlované proměnné na následující období let 2019 až 2021.

Výpočty v rámci aplikace modelu budou provedeny v SW Gretl, pomocné výpočty budou provedeny v MS Excel.

Výpočet pružností

Pružnosti jsou počítány ze strukturální formy modelu, a to pro zjištění a porovnání intenzity působení jednotlivých vysvětlujících proměnných na proměnnou vysvětlovanou. Porovnání se však musí provést v relativním vyjádření proměnných, protože v absolutním vyjádření nelze porovnávat proměnné, které nejsou vyjádřeny ve stejných jednotkách. K porovnání působení vysvětlujících proměnných na vysvětlované proměnné v relativním vyjádření se využívá výpočet pružnosti neboli výpočet elasticity.

Obecný vztah pro výpočet elasticity (pružností) je následující (Tvrdoň, 2019):

$$E = \frac{\partial y}{\partial x_i} \frac{x_i}{\hat{y}} \quad (3.19)$$

Tento vztah reprezentuje výpočet koeficientu pružnosti, který se nejčastěji využívá u lineární funkční formy modelu. Zde platí, že parciální derivací vysvětlované proměnné (y) podle zvolené proměnné vysvětlující (x_i), je vždy získán parametr dané vysvětlující proměnné. (Tvrdoň, 2014)

Vztah je tedy možné podle Gujarati (2004) zjednodušit následovně:

$$\gamma_i \times \frac{x_{it}}{\hat{y}_t} \quad (3.20)$$

Pružnosti jsou počítány z průměrných hodnot jednotlivých proměnných za sledované období.

Oproti tomu tzv. rozdílový koeficient pružnosti bere v úvahu i jinou, než-li 1 % změnu vysvětlující proměnné, jako tomu je u klasického koeficientu pružnosti. Využívá se u nelineárních funkčních forem. (Tvrdoň, 2014)

Vztah rozdílového koeficientu pružnosti je následující (Tvrdoň, 2014):

$$E_{(r)} = E_{(x_i)}^{(1)} + E_{(x_i)}^{(2)} \frac{h}{2!} + \dots + E_{(x_i)}^{(n)} \frac{h}{n!} \quad (3.21)$$

Kde; $E_{(r)}$ rozdílový koeficient pružnosti
 $E_{(x_i)}^m$ koeficient pružnosti m-tého řádu v bodě x_i
 h přírůstek (procentuální změnu) vysvětlující proměnné x_i

Prognózy

Prognózy hodnot vysvětlujících endogenních proměnných se řadí mezi hlavní cíle ekonometrického modelování.

Hušek (2007) uvádí: „*Ekonometrická prognóza nebo-li předpověď je kvantitativním odhadem pravděpodobnosti budoucí hodnoty konkrétní ekonomické veličiny pomocí minulé i současné apriorní i výběrové informace, reprezentované ekonomickou teorií, statistickými daty a odhadnutým ekonometrickým modelem.*“

Termín prognóza neboli předpověď se zpravidla využívá pro extrapolaci modelu do budoucna. Existuje však i extrapolace odhadnutého modelu do minulosti, tedy před intervalem pozorování. Hovoříme o termínu tzv. retroplace.

Rozlišujeme tedy 2 typy předpovědí:

- Ex-post (extrapolace do minulosti)
- Ex-ante (extrapolace do budoucna)

Dle Huška (2007): „*Předpovědi ex-post vysvětlované endogenní proměnné získáme tehdy, můžeme-li stanovit hodnoty jak endogenních, tak vysvětlujících predeterminovaných proměnných v období předpovědi s jistotou.*“ Jinak řečeno, věrohodnost ekonometrického

modelování ověříme určením chyby předpovědi, kterou získáme porovnáním předpovědi ex-post se skutečnou hodnotou predikované endogenní proměnné.

Hušek (2007) dále říká, že: „*O předpovědi ex-ante jde v případě, když hodnotu vysvětlované endogenní proměnné, ani některé nebo často všechny hodnoty vysvětlujících predeterminovaných proměnných v období předpovědi neznáme s jistotou, takže jsme nuceni je také odhadovat či stanovit na základě apriorní informace.*“ Tedy ex-ante lze na rozdíl od předpovědi ex-post, která má charakter pseudopředpovědi, lze považovat za předpověď v pravém slova smyslu.

V ekonometrického prognózování rozlišujeme předpovědi podmíněné a nepodmíněné, tedy absolutní. Stanovit nepodmíněnou předpověď lze v případě, že jsou známy hodnoty všech vysvětlujících predeterminovaných proměnných v modelu v období předpovědi s jistotou. Charakter nepodmíněné předpovědi má tedy ex-post prognóza. Oproti tomu, ex-ante má charakter podmíněné předpovědi.

Platí, že při ekonometrickém prognózování nezískáme na základě odhadnutého ekonometrického modelu předpovědi vysvětlovaných endogenní veličin nikdy zcela přesně, ale s určitou chybou. Tato chyba předpovědi představuje odchylku předpovědi od skutečné hodnoty predikované vysvětlované proměnné v období předpovědi. Jinak řečeno, chybu předpovědi získáme porovnáním předpovědi a skutečné hodnoty predikované vysvětlované proměnné. Určení chyby předpovědi nám pomáhá ověřit vhodnost ekonometrického modelu k prognózování. (Hušek, 2007)

Podle Huška (2007) jsou nejčastějšími faktory ovlivňující velikost a variabilitu chyby předpovědi:

- Stochastický charakter modelu (vznik odchylek předpovědí vysvětlovaných endogenních proměnných od jejich skutečných hodnot i v případě známých hodnot parametrů s jistotou)
- Náhodná standardní chyba (hodnoty odhadnutých parametrů získané z jednoho výběru pozorování se určitou měrou odchylojí od skutečných hodnot parametrů modelu)

- Chybná specifikace odhadnutého ekonometrického modelu v období předpovědi (z důvodu nestability v čase)
- Chyby měření proměnných modelu (např. v důsledku dodatečné revize dat)
- Kvalita dat (především rozsah výběru a jeho reprezentativnost)
- Změna očekávání ekonomických subjektů (nebo např. změna hospodářské politiky)

Pro ověření kvality prognózy poskytované výsledným modelem bude v této diplomové práci provedena ex-post prognóza na 3 poslední období, tedy na roky 2016-2018. Pro stanovení ex-ante prognózy vysvětlované endogenní proměnné na 3 následující období, budou do ekonometrického modelu dosazeny odhady budoucích hodnot vysvětlujících proměnných v letech 2019-2021. Na základě těchto provedených prognóz, bude možné provést ex-ante prognózu vysvětlované endogenní proměnné na 3 následující období, tedy na roky 2019-2021.

4 Teoretická východiska

4.1 Pivo

Jednu z nejznámějších definic piva použili Basařová a Hlaváček (1999): „*Pivo je slabě alkoholický nápoj vyráběný z obilného sladu, vody a chmele. Z uvedených tří základních složek se pivo vyrábí působením mikroorganismů pivovarských kvasinek.*“


Podle Chládky (2007) je definice piva, zaměřená především na tuzemské prostředí následující: „*v Čechách vyráběné pivo je slabý alkoholický nápoj, který vznikl řízeným kvašením cukernatého roztoku, povařeného s chmelem nebo chmelovým výrobkem, kvašený vybraným kmenem pivovarských kvasinek při technologicky určených teplotách a dobách hlavního kvašení a ležení piva. Jako zdroj cukru se pro pivo používá v naší zemi většinou škrob, obsažený v ječném sladu; pokud se výjimečně nahrazuje jinou škrobnatou surovinou nebo přímo cukrem, mluvíme o surogaci a použitá náhrada je surogát.*“

4.2 Spotřeba piva

Říká se, že Češi jsou největšími konzumenty na světě. Na konci roku 2018 organizace Brewers of Europe, která sdružuje národní pivovarnické asociace včetně Českého svazu pivovarů a sladoven, vydala ročenku Pivní statistiky EU. Čísla v této ročence, která jsou shromážděna za rok 2017, který je zatím posledním rokem, za který jsou tato data shromážděna a poskytnuta, tento fakt potvrzují.

Následující graf ukazuje, že Česká republika podle dat Brewers of Europe za rok 2017 drží prvenství ve spotřebě piva na jednoho obyvatele v hodnotě 138 litrů za rok. Následující tři místa v žebříčku patří naším hraničním sousedům Rakousku (105 litrů na jednoho obyvatele za rok), Německu (101 litrů na jednoho obyvatele za rok) a Polsku (97 litrů na jednoho obyvatele za rok). Ve Slovensku byla za rok 2017 spotřeba 72 litrů piva na jednoho obyvatele za rok. (Brewersofeurope, 2019)

Obrázek 1: Spotřeba piva na jednoho obyvatele za rok v litrech



Zdroj: Brewersofeurope.com, 2019

V celkové spotřebě piva v celé zemi, tedy již ne na obyvatele, jsme z celé EU, jak je možno vidět na obrázku č. 28, který je vložen v příloze, až na osmém místě, což však vzhledem k rozloze České republiky není příliš překvapující. Česká republika drží však prvenství nejen ve spotřebě piva na obyvatele, ale také v jeho ceně, jak ukazuje následující obrázek č. 29 z průzkumu od Deutsche bank, který je vložen v příloze. V průzkumu byly porovnávány ceny jednoho piva (tedy 0,5 litru) v hospodách, které se nachází v oblasti většího počtu cizinců. (Echo24, 2019; Insider, 2019)

Český svaz pivovarů a sladoven také představil data za rok 2018 ze své dlouhodobé studie Pivo v české společnosti, kterou připravovalo Centrum pro výzkum veřejného mínění Sociologického ústavu AV ČR (CVVM). Tento výzkumný projekt probíhá již od roku 2004 a studie z roku 2018 pracovala s daty získanými od téměř tisícovky respondentů dospělé tuzemské populace.


Podíl konzumentů piva se v čase mění. U mužů se potvrzuje trend úbytku takových, kteří konzumují pivo alespoň někdy. Jejich podíl se od roku 2015 konstantně snižuje z 91 % na současných 86 %. U žen je to 49 %, z čehož vyplývá, že v ČR pivo konzumuje bezmála každá druhá žena.

U mužů v nejmladší věkové skupině 18-29 let tvoří konzumenti piva neuvěřitelných 90 %. Je to dokonce více, než ve věkové skupině 30-44 let, kde konzumenti tvoří úctyhodných 88 %. Konzumentů ve věkové skupině 46-59 let je již méně a to rovných 84 %, stejně jako u konzumentů nad 60 let.

U žen je to podstatně méně, opět platí, že největší zastoupení má věková skupina 18-29 let, nicméně současně s dalšími věkovými skupinami 30-44 let a 45-59 let. Pod 50 % tvoří pouze věková skupina žen nad 60 let a to 49 %.

Martina Ferencová, výkonná ředitelka Českého svazu pivovarů a sladoven k velké oblibě konzumace piva dodává: „Roli hraje čím dál pestřejší výběr piva, ale také skutečnost, že stále více žen si uvědomuje jeho pozitiva, jež jsou doložena odbornými studiemi. Pivo má

Obrázek 2: Pivo ve společnosti



Zdroj: Ceske-pivo.cz, 2019

kupříkladu nízkou kalorickou hodnotu a obsahuje mnoho vitamínů, minerálů a přírodních antioxidantů. Je i vhodným nápojem po sportu, samozřejmě v přiměřeném množství.“


Čeští milovníci piva mužského pohlaví vypijí v průměru 7,6 půllitru za týden. U žen se týdenní konzumace piva vyšplhala na 2,7 půllitrů. Zajímavá je i frekvence konzumace, kde je vidět, že na tom ženy nejsou oproti mužům vůbec špatně. V průměru pivo konzumují 1,9 dnů v týdnu. U mužů je to ještě více, a to 3,5 dnů v týdnu. (Ceske-pivo, 2019)

Projekt „Pivo v české společnosti“ probíhá již od roku 2004. Analýzy jsou prováděny vždy na souboru respondentů s dosaženým věkem alespoň 18 let a ve sledovaných oblastech mapují trendy od roku 2004 do roku 2018. Přesné znění otázek je uvedeno v příloze.

Následující graf zachycující procentuální podíl konzumentů piva mezi muži a ženami, kteří odpovídali na otázku, zda pijí pivo, ukazuje, že se podíly konzumentů především u mužů, v průběhu let příliš nemění. Nejmenší podíl má právě poslední sledovaný rok 2018 a to 86 % konzumentů. Naopak největší podíl má první sledovaný rok 2004, společně s rokem 2005 a to neuvěřitelných 93 %.

U žen jsou podíly v jednotlivých letech již značně proměnlivější. Již na první pohled je patrný velký úbytek konzumentů v roce 2008, kterých bylo ještě v roce 2007 60 % a o rok později klesl podíl o deset procentních bodů na 50 %. Stejný úbytek nastal o 10 let později v roce 2018, ve kterém byl podíl konzumentů mezi ženami pouhých 49 %, tedy nejméně z celého sledovaného období. Jednalo se tak o úbytek deseti procentních bodů oproti roku 2017. Zároveň se jedná o první úbytek od roku 2015, od kterého podíl konzumentů mírně rostl. Výkyvy mohou být vysvětleny také povahou výzkumu a velikostí zkoumaného vzorku konzumentů.

Graf 1: Podíly konzumentů piva mezi muži a ženami



Zdroj: vlastní zpracování dle CVVM SOÚ AV ČR, 2019


Následující graf zachycuje průměrné množství piva konzumovaného týdně muži a ženami v půllitrech opět od roku 2004 do roku 2018. Mezi významné ukazatele patří také objem konzumace. Tu má smysl sledovat u těch, kteří pivo konzumují pravidelně, a v tomto případě to bylo realizováno prostřednictvím dotazu na průměrný počet půllitrů za týden, jde tak o sledování trendu objemu konzumace piva u těch, kteří jej konzumují.

Jak je patrné z grafu, rekordní průměrnou spotřebu mezi muži vykazuje rok 2007 a to průměrně 9,5 půllitrů piva za týden. Nejnižší průměrnou spotřebu vykazuje opět poslední sledovaný rok 2018 a to 7,6 půllitrů týdně. Stejně nízkou spotřebu vykazuje již pouze rok 2013. Velký meziroční nárůst byl zaznamenán v již zmíněném roce 2007, kde jde oproti průměrnému množství 7,9 půllitrů konzumovaného piva týdně, o nárůst o 1,6 půllitrů piva týdně.

U žen se jedná v posledním sledovaném roce 2018 naopak o nárůst z předešlého roku 2017, kdy bylo průměrně zkonsumováno 2,3 půllitrů týdně na 2,7 půllitrů za týden. Po celé sledované období nenastal žádný výrazný výkyv a hodnoty spotřeby ve sledovaném období se kromě posledního roku 2018 pohybují v rozmezí 1,9-2,5 půllitrů týdně. Nárůst v posledním sledovaném roce vysvětluje Jiří Vinopal z Centra pro výzkum veřejného mínění, které spadá pod Sociologický ústav AV ČR následovně: „Jedná se totiž o důsledek skutečnosti popsané výše čili snížení množství takových, které podle svých slov alespoň někdy

pijí pivo. Tyto ženy, sváteční pijačky piva, totiž průměrnou hodnotu spotřeby přirozeně snižují (pijí piva nejméně ze všech). Pakliže v letošním roce tyto ženy z výpočtu průměrné spotřeby vypadávají, neboť prohlásily, že pivo nepijí vůbec, je průměrná hodnota vypočítávána pouze z těch, které mají spotřebu vyšší.“ Podle něj podporuje tento fakt také skutečnost, že k poklesu konzumentů piva mezi ženami dochází v posledních letech především mezi ženami s maturitním a vysokoškolským vzděláním. Jinak řečeno, na daném poklesu se podílejí kromě společenského klima oslabující ochotu žen takovou skutečnost ve výzkumu sdělovat, také samotný fakt úbytku žen konzumujících pivo. (CVVM, 2019)

Graf 2: Týdenní konzumace piva

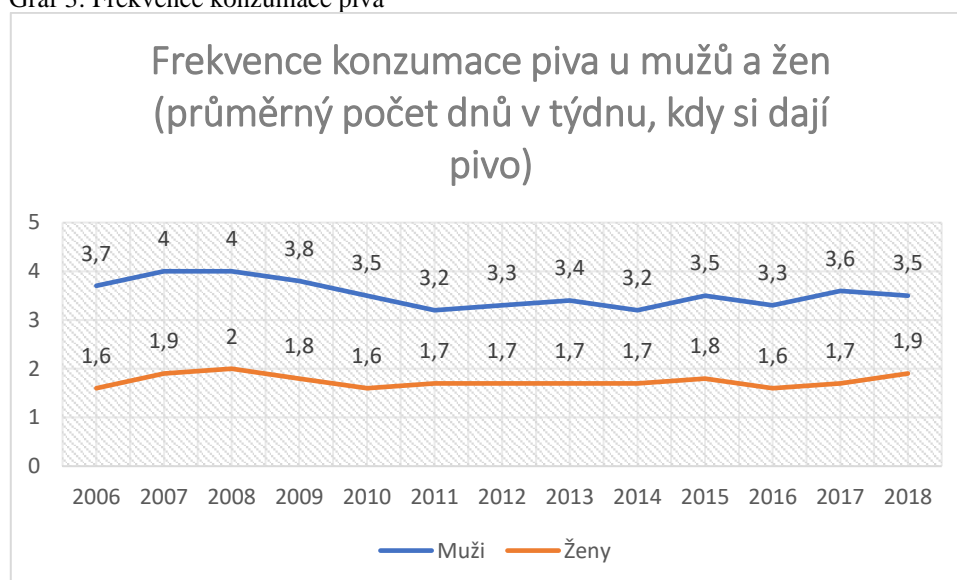


Zdroj: vlastní zpracování dle CVVM SOÚ AV ČR, 2019

Následující graf zobrazuje frekvenci konzumace piva u mužů a žen od roku 2006 do roku 2018, respektive průměrný počet dnů v týdnu, kdy pivo konzumují. Graf je vytvořen ze stejného výzkumu, jako grafy předcházející. U mužů je evidentní, že meziroční hodnoty mají znatelně větší výkyvy, než je tomu u žen. Platí, že nejmenší průměrný počet dnů v týdnu konzumace piva u mužů je 3,2 půllitrů a takové hodnoty výzkum zaznamenal v roce 2011 a 2014. Nejvyšší hodnoty pak opět ve dvou letech, a to v roce 2007 a v roce následujícím, 2008. To byla výzkumem zjištěna průměrná hodnota celých 4 půllitrů piva. Klesajícího trendu si je možné všimnout právě u již zmíněného roku 2008, který trval až do roku 2011, jehož hodnota zároveň znázorňuje opět již zmíněnou nejnižší hodnotu z celé časové řady.

U žen jsou výkyvy hodnot značně mírnější. Dokonce je možné si povšimnout stagnujícího trendu mezi lety 2011 až 2014, kdy byla průměrná hodnota konzumace piva 1,7 půllitrů týdně. Nejnižší hodnota ve výzkumu reprezentuje 1,6 půllitrů piva týdně, a to v letech 2006, 2010 a 2016. Nejvyšší hodnotou je 2 půllitry piva týdně v roce 2008, tedy ve stejném roce jako u mužů. Je možné si také všimnout rostoucí tendence týdenní konzumace piva u žen od roku 2016. (CVVM, 2019)

Graf 3: Frekvence konzumace piva




Zdroj: vlastní zpracování dle CVVM SOÚ AV ČR, 2019

Následující dva grafy vyjadřují postoj ke spotřebě piva v České republice z pohledu mužů a žen. Jiří Vinopal z Centra pro výzkum veřejného mínění říká: „I přes různé výkyvy a celkově mírně klesající trendy v nedávných letech jsou obyvatelé České republiky dlouhodobě na špičce celosvětového žebříčku konzumace piva.“ Dodává však, že tento fakt není mnohdy mezi účastníky výzkumu brát jako pozitivní, respektive něco, čím by se oni sami měli chlubit. (CVVM, 2019)

V následujícím grafu budou vyhodnoceny výsledky z roku 2018. Jak ukazuje graf, týkající se mužů, největší část z nich, konkrétně 35 % vyjadřuje nad tím tímto prvenstvím hrdost. Jak je možné si všimnout v grafu druhém, týkajícího se žen, většina jich již takovou hrdost necítí, hrdost vyjadřuje pouze 14 % dotázaných žen. Z tohoto výzkumu by se tedy mohlo usoudit, že ženy jsou k českému prvenství konzumace piva značně kritičtější. K takovému výroku bychom však potřebovali získat širší vzorek zkoumání. Stud cítí


pouhých 8 % dotázaných mužů a 22 % dotázaných žen. 29 % mužů a 23 % žen si není jisto a má smíšené pocity. Těm, kterým na tom vůbec nezáleží a je jim to jedno, není zanedbatelné množství, z mužů takový postoj vyjádřilo celých 25 % a ještě zajímavější je statistika u žen, kdy takový postoj vyjádřilo 38 % žen, tedy tato skupina reprezentuje největší část dotázaných žen. (CVVM, 2019)

Graf 4: Postoj ke spotřebě piva muži



Zdroj: vlastní zpracování dle CVVM SOÚ AV ČR, 2019

Graf 5: Postoj ke spotřebě piva ženy



Zdroj: vlastní zpracování dle CVVM SOÚ AV ČR, 2019

Podle Jiřího Vinopala z Centra pro výzkum veřejného mínění, hrdost nad prvenstvím vyjadřuje spíše mladší věková kategorie, a naopak u starší věkové kategorie je pocit hrdosti méně častý. U starších věkových kategorií narůstají u mužů smíšené pocity a u žen dokonce pocit studu. Výzkum dokonce uvádí, že hrdost na prvenství slábne v souvislosti s vyšším vzděláním. Jinak řečeno, s růstem vzdělání slábne pocit hrdosti, a to jak u mužů, tak u žen. (CVVM, 2019)

Český svaz pivovarů a sladoven dále zveřejnil hospodářské výsledky pivovarského oboru za rok 2018. Z výsledků vyplývá, že uvedený rok byl pro české pivovarství úspěšný. Celkový výstav dosáhl rekordních 21 272 tis. hl. piva.

To podpořila především zahraniční poptávka. Podle českého svazu pivovarů a sladoven, největší podíl na spotřebě piva na trhu mají ležáky (tedy spodně kvašená piva se stupňovitostí 11 – 12 %) s 50,3 %, následuje pivo výčepní s 45,2 % a ostatní (např. nealkoholická piva, pivní speciály) s 4,5 % podílem. Právě nealkoholických piv vyprodukovaly pivovary 620 tis.hl, což je 7,3 % meziroční nárůst oproti předcházejícímu roku.

Co se týče exportu, činí 5 157 tis. hl piva, což je oproti 395 tis. hl importovaného piva pro výrobce značně pozitivní. Export tak meziročně vzrostl o 11,8 %. Export mimo EU meziročně posílil o neuvěřitelných 20 %, díky čemuž dosáhl téměř čtvrtiny z celkového vývozu.

Čepované pivo (tzv. on-trade) se na spotřebě podílelo ze 36 % a balené pivo (tzv. off-trade) z 64 %. V podílech spotřeby podle obalů vede pivo lahvové (40 %), následuje pivo sudové (34 %) a s velkým odstupem poté PET lahve (12 %), plechovky (11 %) a cisterny (3 %).

Největšími exportními trhy jsou pro české pivo tradičně Slovensko a Německo, kde vzrostl export o 14 % (Slovensko), respektive 9 % (Německo). Dále jsou to Rusko, Polsko a Švédsko. (Ceske-pivo, 2019)

Obrázek 3: Hospodářské výsledky pivovarského oboru 2018



Zdroj: Ceske-pivo.cz, 2019

4.3 Ekonometrie

Podle Huška (2007) „*Ekonometrii lze stručně charakterizovat jako kvantitativní ekonomickou disciplínu zabývající se měřením a empirickou verifikací reálných ekonomických vztahů a závislostí.*“ A dále uvádí, že vznik ekonometrii jako samostatného vědního oboru se datuje již od roku 1930 od založení Econometric Society v USA.

Asteriou a Hall (2007) definují ekonometrii následovně: „*Ekonometrie znamená doslova "měření" (což je význam řeckého slova "metrics" v ekonomii. Ekonometrie zahrnuje všechny statistické a matematické techniky, které se používají při analýze ekonomických údajů. Hlavním cílem použití těchto statistických a matematických nástrojů v ekonomických datech je pokusit se prokázat nebo vyvrátit určité ekonomické návrhy a modely*”

Podle Mukrase (1993) ekonometrie je společensko-vědní předmět, který při analýze využívá ekonomických vztahů ekonomickou teorii, matematiku a statistickou teorii. Jako hlavní cíle uvádí: testování hypotéz v ekonomické teorii; vytváření politických doporučení a prognózy. Aby bylo dosaženo jednoho nebo všech těchto cílů, musí ekonometrici využívat současně ekonomickou teorii, matematiku a statistickou teorii. (Mukras, 1993)

Gujarati (2004) ve své knize uvádí celou řadu definic ekonometrie převzatých z jiných publikací, především předních ekonometrů. Například: „*Ekonometrii lze definovat jako kvantitativní analýzu skutečných ekonomických jevů založených na souběžném vývoji teorie a pozorování, souvisejících s vhodnými metodami odvozování.*“ (Tintner, 1968) či definice následující: "*Ekonometrie může být definována jako společenská věda, ve které jsou nástroje ekonomické teorie, matematiky a statistické odvození aplikovány na analýzu ekonomických jevů.*" (Goldberger, 1964)

4.4 Ekonomická teorie

Ekonomická teorie vychází z hypotézy, že rozhodujícími faktory, které určují poptávku po jakékoliv komoditě na trhu, je její cena, ceny substitučního či komplementárního charakteru zboží a úroveň disponibilního příjmu spotřebitele včetně spotřebních preferencí spotřebitele. Zároveň však platí, že na poptávku působí ještě další vlivy, mezi které bychom mohli zařadit například i míru nezaměstnanosti. Obvykle však model obsahuje pouze tři nebo čtyři vysvětlující proměnné a vliv nepodstatných faktorů je

zahrnut do náhodné složky modelu. Platí, že výroba a potřeby se vzájemně podmiňují a ovlivňují. Struktura produkce, a tedy i výroby se odvíjí od struktury potřeb. Současně platí, že rozvoj výroby ovlivňuje dynamiku vývoje potřeb.

Na základě těchto informací lze vyjádřit poptávkovou funkci spotřebitele po určitém zboží ve následujícím obecném tvaru: $Q_p = f(P_p, P_j, Y, V)$ (3.22)

Kde; Q_p výše poptávky po určitém zboží

P_p cena tohoto konkrétního zboží

P_j cena jiného zboží

Y disponibilní reálný příjem spotřebitele

V umělá proměnná (tzv. dummy proměnná) měřící spotřebitelské preference

V případě jednoduché lineárního tvaru poptávkového modelu je možná následující specifikace: $Q_p = \beta_0 + \beta_1 P_p + \beta_2 P_j + \beta_3 Y + u$ (3.23)

Jedná se tedy o mikroekonomický model reprezentující stochastickou lineární funkci. Změny závislé endogenní proměnné Q_p jsou zde vysvětlovány z hlediska mikroekonomické teorie třemi nezávislými exogenními proměnnými a to P_p (cena konkrétního zboží), P_j (cena jiného zboží) a Y (disponibilní reálný příjem spotřebitele). Náhodná složka „ u “ zahrnuje také chyby, které vznikají vynecháním pro nás nepodstatných proměnných.

Parametr β_0 jakožto počáteční konstanta představuje výši poptávky při nulových hodnotách ostatních vlivů. V souladu s obecnou teorií poptávky předpokládáme, že znaménko neboli směr parametru β_1 je záporný. Důvodem je skutečnost, že požadované množství určitého zboží je nepřímo úměrné ceně tohoto určitého zboží. U parametru β_2 předpokládáme v případě substitutu kladné znaménko neboli směr. U parametru β_3 předpokládáme kladné znaménko z důvodu přímé úměry úrovně reálného disponibilního příjmu a výše poptávky. (Hušek, 2007)

Jedním ze základů analýzy spotřeby je spotřební funkce. Tento pojem pochází od Keynesa, který jej definoval jako přímou závislost zejména na reálném důchodu, kdy spotřeba roste pomalejším tempem oproti důchodu. (Hušek, 2009) Schiller (2004) ji vyjadřuje jako matematický vztah vyjadřující úroveň požadovaných spotřebitelských výdajů při odlišných hladinách důchodu. Dle Holmana (1999) se jedná o funkci, jež vyjadřuje přímo úměrnou závislost spotřeby na disponibilním důchodu a nepřímo úměrnou závislost na reálné úrokové míře.

Nezaměstnanost představuje (mimo jiné) snížení kupní síly obyvatelstva. V ekonomice pak toto snížení vyvolává pokles poptávky po statcích a službách (Čadil, 2011). Se vznikem nezaměstnanosti tedy úzce souvisí pokles životní úrovně nezaměstnaných. Nedostatek finančních prostředků nutí nezaměstnané omezit jejich spotřebu. (Kolibová a Kubicová, 2005).

4.5 **Ekonometrický model**

Ekonometrický model je jedním ze základních nástrojů pro vytváření prognóz vývoje různých ekonomických veličin. Na rozdíl od modelu ekonomický, zkoumá model ekonometrický funkční vztahy mezi ekonomickými proměnnými. Podle Huška je ekonometrický model hlavním nástrojem ekonometrické analýzy. Jedná se o symbolický model převážně deskriptivního, tedy popisného charakteru, který pomocí algebraických vztahů popisuje základní ekonomickou hypotézu. Ekonometrický model umožňuje kvantifikovat intenzitu a směr vzájemného působení ekonomických proměnných v modelu vhodně zvolenými statistickými a ekonometrickými metodami za předpokladu dispozice vhodných statistických dat. Platí, že model musí být správně specifikován z hlediska zahrnutých proměnných, z hlediska analytického tvaru zkoumané závislosti a stochastických předpokladů o rozdělení pravděpodobnosti náhodných složek. (Hušek, 1992)

Existují následující typy modelů:

- Jednorovnicový model – má charakter stochastického regresního modelu, který vyjadřuje jednu vysvětlovanou endogenní proměnnou v závislosti na jedné či více vysvětlujících exogenních či zpožděných endogenních proměnných, které jsou měřitelné a na náhodné složce, která měřitelná není.

Obecný ekonomický zápis takového jednorovnicového modelu může mít následující

tvar:
$$y = f(x) \tag{3.24}$$

Kde; y znázorňuje vysvětlovanou proměnnou

x znázorňuje vysvětlující proměnnou

- Vícerovnicový model zcela nebo zdánlivě nezávislých rovnic – v takovém modelu, lze každou z rovnic zkoumat odděleně, stejně jako jednorovnicový stochastický model. Je také možné celou soustavu chápat jako vícerozměrný regresní model. O model zdánlivě nezávislých rovnic jde v případě, nejsou-li náhodné složky „u“ jednotlivých rovnic nezkorelované, zároveň však neexistují žádné vazby mezi endogenními proměnnými. (Hušek, 2007)

Obecný ekonomický zápis takového vícerovnicového modelu může mít následující

tvar:
$$\begin{aligned} y_1 &= f(y_2, x_2, x_3) \\ y_2 &= f(x_2, x_4, x_5) \end{aligned} \tag{3.25}$$

Kde; y_1 znázorňuje vysvětlovanou proměnnou na levé straně a vysvětlující proměnnou na pravé straně

y_2 znázorňuje vysvětlovanou proměnnou na levé straně a vysvětlující proměnnou na pravé straně

x_2, x_3, x_4, x_5 znázorňují vysvětlující proměnné

- Simultánní model – takový model je tvořený soustavou jak vzájemně závislých stochastických, tak i nestochastických rovnic. Charakter simultánnosti spočívá ve skutečnosti, že nezpožděné endogenní proměnné vystupují v jednotlivých rovnicích daného modelu v simultánní roli. To znamená, že jsou současně jak ve funkci vysvětlovaných, tak ve funkci vysvětlujících proměnných. Zároveň jsou určeny k řešení všech rovnic v modelu najednou. (Hušek, 2007)

Obecný ekonomický zápis takového simultánního modelu může mít následující tvar:

$$y_1 = f(y_2, x_2, x_3)$$

$$y_2 = f(y_1, x_2, x_4) \quad (3.26)$$

Kde; y_1, y_2 znázorňují vysvětlovanou proměnnou na levé straně a vysvětlující proměnnou na pravé straně

x_2, x_3, x_4 znázorňují vysvětlující proměnné

V interdependentní soustavě simultánních rovnic neboli v soustavě, kde existuje vzájemná závislost, existují mezi endogenními proměnnými zpětné vazby přímé nebo nepřímé. Zatímco v systémech rekurzivních se vyskytují mezi endogenními proměnnými pouze vazby jednosměrné, tedy vazby příčinné. Zde jsou navíc náhodné složky v různých stochastických rovnicích ve stejných pozorováních vzájemně nezávislé. (Hušek, 2007)

4.6 Druhy proměnných v ekonometrickém modelu

V ekonometrických modelech jsou rozlišovány následující typy proměnných:

- Endogenní proměnné
- Exogenní proměnné
- Predeterminované proměnné
- Náhodné proměnné

Endogenní proměnné jsou proměnnými, které jsou modelem vysvětlovány, proto se také nazývají vysvětlované proměnné. Jsou zpravidla označovány písmenem y s náležitými indexy, které umožňují jednoznačnou identifikaci takové proměnné a její hodnoty v příslušném období (Gujarati, 2004).

Exogenní proměnné se rovněž nazývají vysvětlující proměnné a to proto, že endogenní proměnné vysvětlují. Charakter vysvětlujících proměnných mají vždy. Zpravidla bývají označovány písmenem x . (Hušek, 2007)

Predeterminované proměnné zahrnují všechny exogenní proměnné a také zpožděné endogenní proměnné. Predeterminované se nazývají proto, že jsou jejich hodnoty stanoveny vnějším prostředím. (Hušek, 2007)

Náhodná složka (či chyba) obsahuje vliv všech dalších proměnných, kterou nebyly v modelu zahrnuty. Hodnoty náhodné složky nelze získat měřením. Obsahuje také chyby měření a dále zkreslení plynoucí z volby nevhodného typu funkce. Chyby náhodné složky vznikají například vynecháním nebo opomenutím některé z důležitých vysvětlujících proměnných. Náhodná proměnná je označována písmenem u . (Hušek, 2007)

4.7 AR modely

Autoregresní model (AR model) časové řady je založen na poznatku, že každá hodnota v časové řadě, je v relaci, tedy závislosti s předchozími hodnotami této řady. Autoregresivní model tedy předpovídá budoucí chování založené na chování předešlém, tedy v minulosti. Používá se pro předpovědi, kdy existuje určitá korelace mezi hodnotami v časové řadě a hodnotami, které je předcházejí a které následují. K tomu se používají data z minulosti, proto název autoregresivní (řecká předpona auto - znamená „vlastní“). Tento proces je v podstatě lineární regrese dat aktuálních hodnot, proti jedné nebo více hodnotám předešlým. Proces AR je příkladem stochastického procesu, který má určitou míru nejistoty nebo náhodnosti. Platí tedy, že předpověď budoucích trendů, nebudete mít nikdy stoprocentní přesnost. (VSB, 2019)

5 Vlastní práce

5.1 Ekonomická teorie

Výstup první fáze konstrukce ekonometrického modelu tvoří výběr a popis proměnných, které budou použity v daném ekonometrickém modelu.

5.1.1 Výběr a popis proměnných

1. Spotřebitelská cena piva

Jedná se o průměr cen piva výčepního světlého lahvového a piva světlého sudového.

2. Produkce piva

Jedná se o roční souhrny výroby piva ze sladu (kromě nealkoholického).

3. Míra nezaměstnanosti

Míra nezaměstnanosti reprezentuje podíl nezaměstnaných k ekonomicky aktivním, to znamená k součtu zaměstnaných a nezaměstnaných. Vztah pro výpočet nezaměstnanosti je následující (Holman, 2004): $u = \frac{U}{L+U}$ (3.27)

Kde; u míra nezaměstnanosti

L počet zaměstnaných

U počet lidí bez práce

4. Míra Inflace

Inflace obecně představuje zvyšování cenové hladiny, která má za následek snižování kupní síly peněz. Míra inflace vycházející z dat ČSÚ vyjádřená přírůstkem průměrného ročního indexu spotřebitelských cen reprezentuje procentní změnu průměrné cenové hladiny za 12 posledních měsíců proti průměru 12 předchozích měsíců. (czso.cz, 2019)

5. Platební bilance

Platební bilance zachycuje systematickým způsobem ekonomické transakce se zahraničím (tj. mezi rezidenty a nerezidenty) za určité časové období. Základní struktura platební bilance vycházející z Příručky k sestavování platební bilance mezinárodním měnovým fondem (5. vydání, 1993) zahrnuje běžný, kapitálový a finanční účet, změnu rezerv. (czso.cz, 2019)

6. Průměrná mzda

Průměrná mzda vyjadřuje průměrnou měsíční mzdu v absolutním vyjádření v uvedených letech sledovaného období.

7. Spotřebitelská cena vína

Jedná se o průměrnou roční spotřebitelskou cenu vína na základě dat z ČSÚ.

5.2 Tvorba ekonomického a ekonometrického modelu

Formulace ekonomického modelu

$$y_t = fce(x_{1t}, x_{2t}, x_{3t}, x_{4t})$$

Zápis ekonometrického modelu

$$y_t = fce(\gamma x_{1t} + \gamma x_{2t} + \gamma x_{3t} + \gamma x_{4t} + u_{1t})$$

Deklarace proměnných včetně uvedení jednotek

Endogenní proměnná:

y_t spotřeba piva [l/os /rok]

exogenní proměnné:

x_{1t} jednotkový vektor [J. V.]

x_{2t} spotřebitelská cena piva [Kč/l]

x_{3t} produkce piva [tis. hl/rok]

x_{4t} míra nezaměstnanosti [%]

u_tstochastická složka [l/os /rok]

Předpokládané vztahy s již zmíněnou endogenní proměnnou jsou následující:

- S růstem spotřebitelské ceny piva se snižuje spotřeba piva
- S růstem produkce piva se zvyšuje spotřeba piva
- S růstem míry nezaměstnanosti nelze jednoznačně určitě směr spotřeby piva, neboť se nabízí dvě možnosti:
 - a) S růstem míry nezaměstnanosti se snižuje spotřeba piva
 - b) S růstem míry nezaměstnanosti se zvyšuje spotřeba piva
- S růstem míry inflace se snižuje spotřeba piva
- S růstem platební bilance se zvyšuje spotřeba piva
- S růstem průměrné mzdy se zvyšuje spotřeba piva
- S růstem spotřebitelské ceny vína se zvyšuje spotřeba piva


5.3 Sběr dat

5.3.1 Datová tabulka

Datová tabulka (Tabulka 4) s hodnotami proměnných, které byly použity při odhadu ekonometrického modelu, je vložena v příloze.

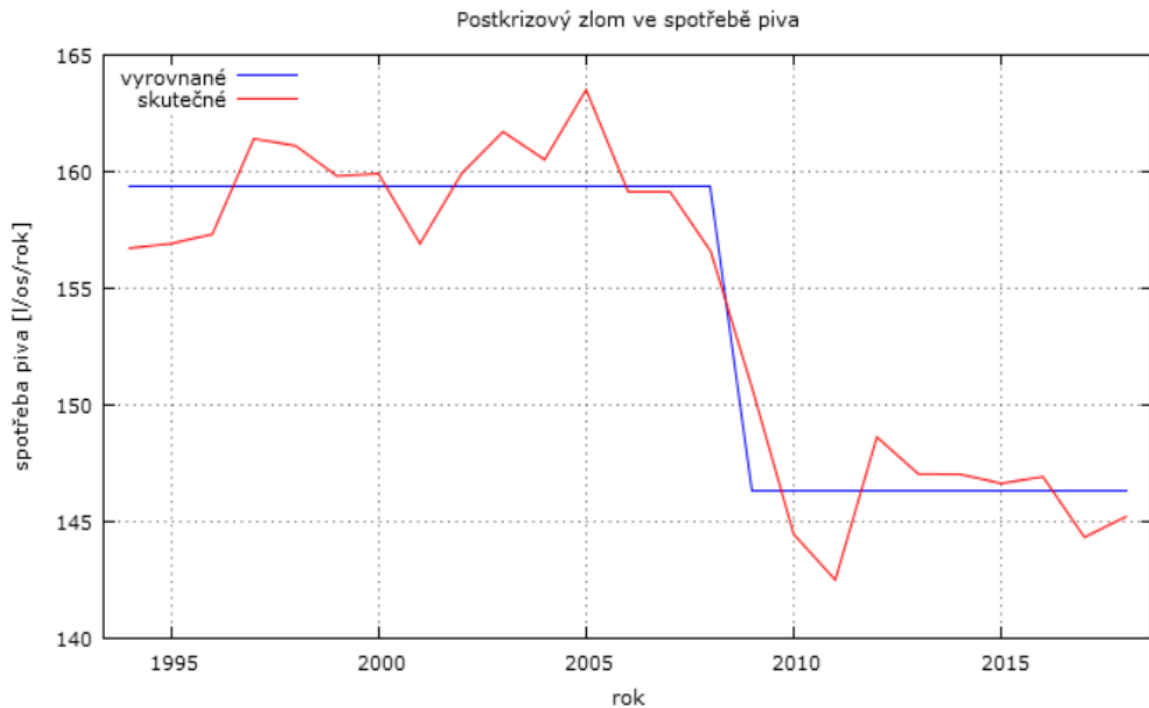
5.3.2 Vývoj proměnných v čase

Vývoj spotřeby piva



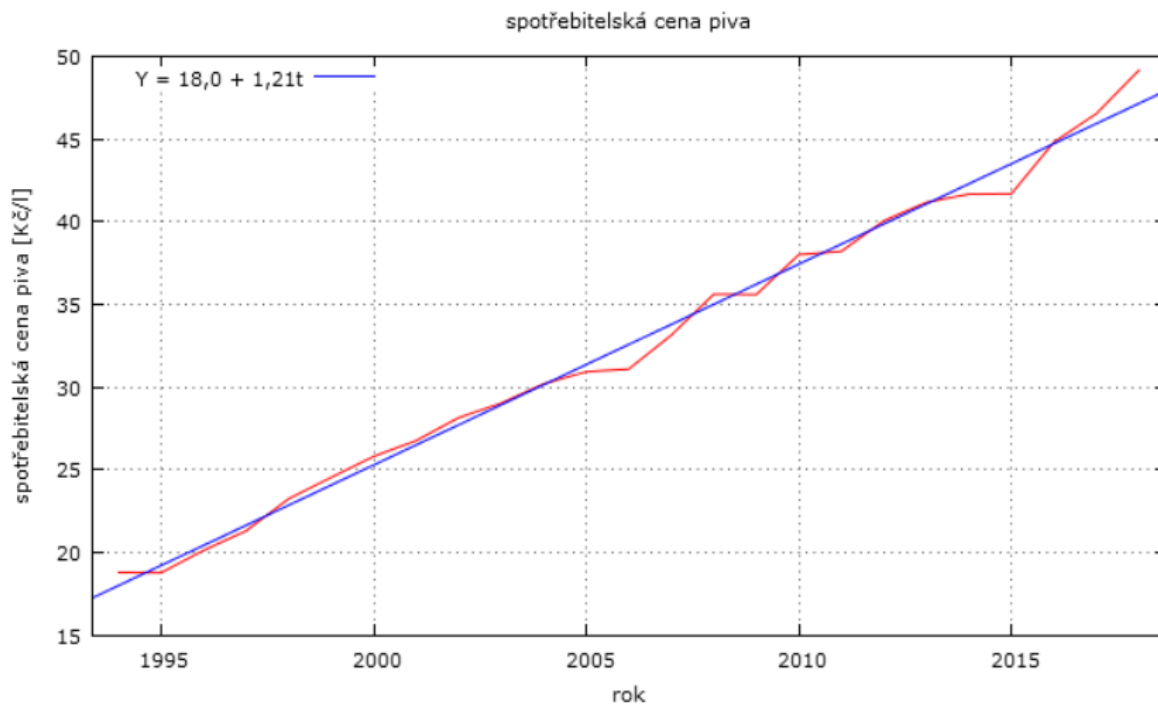
Graf 6: Vývoj spotřeby piva
Zdroj: vlastní zpracování v SW Gretl, 2019

Z grafu je patrná klesající tendence v tuzemské spotřebě piva, což dokazuje i lineární trendová funkce, podle které průměrný meziroční pokles ve spotřebě piva byl 0,741 l/os/rok. Ovšem při detailnějším rozboru grafu je patrné, že v letech hospodářské krize došlo k náhlému propadu ve spotřebě piva, který trvá dodnes. Tento propad je zachycen v následujícím grafu modelem, který zachycuje pouze samotný propad, který na základě odhadnutých parametrů činí 13,03 l/os/rok ceteris paribus. Ovšem je možné, že tento propad se dá odůvodnit i jinými příčinami, a proto bude dále v této diplomové práci použit model vícenásobné regrese, kde budou tyto možné vlivy modelovány.



Graf 7: Postkrizový zlom ve spotřebě piva
Zdroj: vlastní zpracování v SW Gretl, 2019


Vývoj spotřebitelské ceny piva



Graf 8: Vývoj spotřebitelské ceny piva
Zdroj: vlastní zpracování v SW Gretl, 2019

Na grafu spotřebitelské ceny piva v České republice je zcela zřejmé, že od roku 1994 až do roku 2018 docházelo k pozvolnému růstu ceny piva, kdy docházelo občasně k chvilkové stagnaci. Průměrný meziroční přírůstek ve spotřebitelské ceně piva ve sledovaném období činil 1,21 Kč/l.


Vývoj produkce piva



Graf 9: Vývoj produkce piva
Zdroj: vlastní zpracování v SW Gretl, 2019

Ke grafu, věnujícímu se produkce piva, lze konstatovat, že v roce 2008 přišel výrazný propad v produkci, který byl pravděpodobně způsobem globální ekonomickou krizí. Od roku 2010 se produkce piva začala opět zvyšovat. Průměrný meziroční přírůstek v produkci piva ve sledovaném období činil 22,5 tis. hl/rok.

Vývoj míry nezaměstnanosti




Graf 10: Vývoj míry nezaměstnanosti

Zdroj: vlastní zpracování v SW Gretl, 2019

Na grafu věnujícímu se obecné míře nezaměstnanosti je dle rovnice trendu vidět, že má tendenci od roku 2000 klesat. Za zmínku stojí roky 2008 a 2009, kdy se projevily následky americké hypoteční krize zvýšenou nezaměstnaností. Od roku 2013 míra nezaměstnanosti neustále klesá. Průměrný meziroční pokles míry nezaměstnanosti ve sledovaném období činil 0,0624 p.b.


Vývoj míry inflace



Graf 11: Vývoj míry inflace
Zdroj: vlastní zpracování v SW Gretl, 2019

Z grafu věnujícímu se průměrné roční míře inflace lze konstatovat, že má klesající tendenci. V roce 1994 byla průměrná inflace 10 %, v roce 2018 to bylo již 2,1 %. Za zmínku jistě stojí roky 2003 a 2005, kde míra inflace činila 0,1 %, respektive 0,3 %, došlo tak téměř k deflaci, která by pro českou ekonomiku měla jistě negativní dopad. Průměrný meziroční pokles míry inflace ve sledovaném období činil 0,321 p.b.


Vývoj platební bilance



Graf 12: Vývoj platební bilance
Zdroj: vlastní zpracování v SW Gretl, 2019

V grafu platební bilance je patrná stoupající tendence s výkyvem od roku 2007 do roku 2010, od kterého se platební bilance již znovu zvyšuje. V roce 2018 hodnota platební bilance dosáhla výše 6 299,321 mil. Kč. Průměrný meziroční přírůstek v platební bilanci ve sledovaném období činil 203 mil. Kč.

Vývoj průměrné mzdy

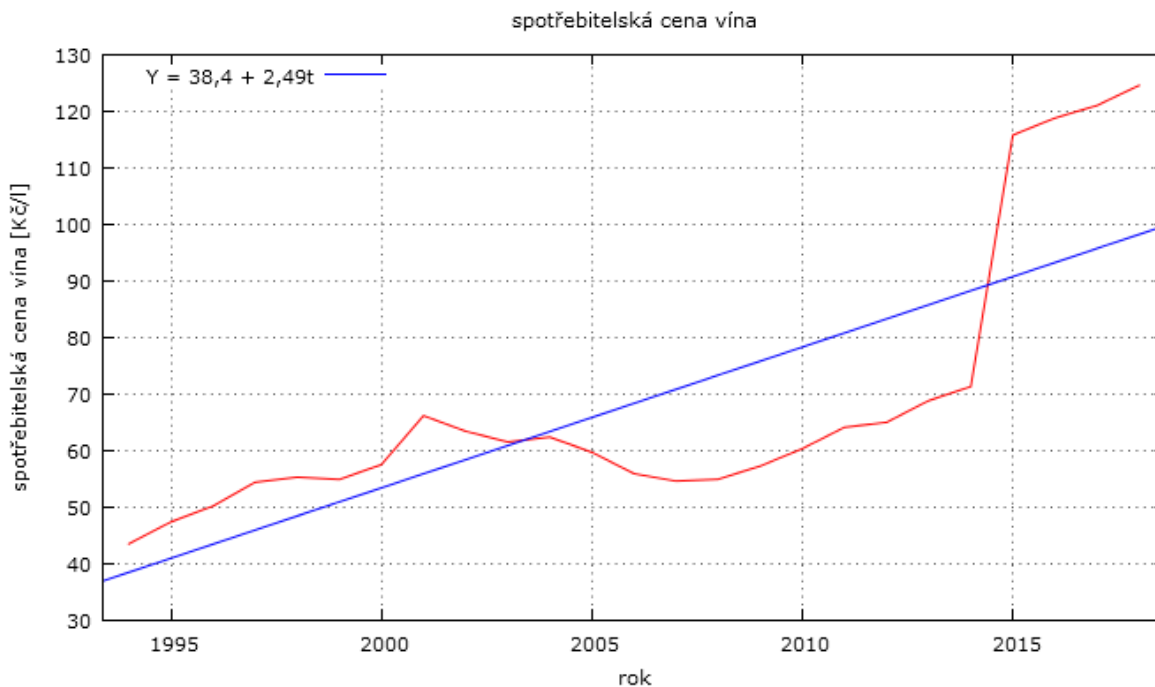


Graf 13: Vývoj průměrné mzdy

Zdroj: vlastní zpracování v SW Gretl, 2019

Z grafu průměrné výše měsíční mzdy je zcela patrná stoupající tendence, kdy v roce 2018 hodnota průměrné měsíční mzdy dosahovala 30 802 Kč. Průměrný meziroční přírůstek v průměrné měsíční mzdě ve sledovaném období činil 897 Kč.

Vývoj spotřebitelské ceny vína



Graf 14: Vývoj spotřebitelské ceny vína
Zdroj: vlastní zpracování v SW Gretl, 2019

Z grafu věnujícímu se spotřebitelské ceně vína je možné konstatovat, že spotřebitelská cena vína má stoupající tendenci. Průměrný meziroční přírůstek ve spotřebitelské ceně vína ve sledovaném období činil 2,49 Kč/l.

5.3.3 Deskriptivní statistiky

Tabulka 1: Deskriptivní statistiky

Popisné statistiky, za použití pozorování 1994 - 2018				
Proměnná	Průměr	Medián	Minimum	Maximum
Sp_P	154,14	156,9	142,47	163,5
SpC_P	32,57	34,36	18,76	54,16
Pr_P	18289,82	18253	16896	20134
Mn	6,08	6,3	2	8,8

Zdroj: vlastní zpracování v MS Excel, 2019

5.3.4 Korelační matice

Tabulka 2: Korelační matice

Korelační koeficienty, za použití pozorování 1994 - 2018, 5% kritická hodnota (oboustranná) = 0,3961 pro n = 25					
Sp_P	SpC_P	Pr_P	Mn	postkrize	
1,0000	-0,7975	0,2134	0,3790	-0,9490	Sp_P
	1,0000	0,2307	-0,2585	0,8466	SpC_P
		1,0000	-0,2970	-0,1527	Pr_P
			1,0000	-0,2643	Mn
				1,0000	postkrize

Zdroj: vlastní zpracování v MS Excel dle SW Gretl, 2019

Vysoká korelace se vyskytla mezi spotřebitelskou cenou piva a dummy proměnnou postkrize, což značí, že může hrozit multikolinearita. Nicméně to neznamená, že multikolinearity v modelu opravdu je. Pro vyloučení multikolinearity bude později proveden VIF test. Naopak žádoucí vysoká korelace mezi vysvětlující proměnnou a vysvětlovanou proměnnou se vyskytla pouze u dummy proměnné postkrize.

5.4 Odhad parametrů ekonometrického modelu

Nejprve byly k odhadu použity proměnné uvedené v kapitole 5.4. Jelikož však odhadnutý model vykazoval nevýznamnost několika parametrů, bylo potřeba některé proměnné z modelu vyjmout. Byly odstraněny proměnné míra inflace, platební bilance, průměrná mzda a spotřebitelská cena vína, a naopak byly v modelu zanechány proměnné spotřebitelská cena piva, produkce piva, míra nezaměstnanosti a dummy proměnná postkrize.

Druhý odhad modelu dopadl citelně lépe. Významnost parametrů v odhadovaném modelu i významnost celého modelu byla vysoká. Všechny parametry byly statisticky významné.

Výstup odhadu parametrů ekonometrického modelu v SW Gretl je uveden níže:

Obrázek 4: Výstup 2. odhadu

Model 2: OLS, za použití pozorování 1994-2018 (T = 25)					
Závisle proměnná: Sp_P					
	koeficient	směr. chyba	t-podíl	p-hodnota	
const	115,454	13,8802	8,318	6,35e-08	***
SpC_P	-0,195983	0,109002	-1,798	0,0873	*
Pr_P	0,00239424	0,000820347	2,919	0,0085	***
Mn	0,787823	0,224666	3,507	0,0022	***
postkrize	-8,77926	1,99547	-4,400	0,0003	***
Střední hodnota závisle proměnné		154,1432			
Sm. odchylka závisle proměnné		6,868858			
Součet čtverců reziduí		64,60221			
Sm. chyba regrese		1,797251			
Koeficient determinace		0,942949			
Adjustovaný koeficient determinace		0,931538			
F(4, 20)		82,64012			
P-hodnota (F)		3,81e-12			

Zdroj: vlastní zpracování dle SW Gretl, 2019

V SW Gretl byly odhadnuty parametry ekonometrického modelu následovně:

$$y_{1t} = 115,454 - 0,195983x_{2t} + 0,00239424x_{3t} + 0,787823x_{4t} - 8,77926x_{5t} + u_{1t}$$

5.5 Statistické a ekonometrické ověření

5.5.1 Ekonometrické ověření - Test multikolinearity

Obrázek 5: Test multikolinearity – VIF

Faktory zvyšující rozptyl (VIF)	
Minimální možná hodnota = 1.0	
Hodnoty > 10.0 mohou indikovat problém kolinearity	
SpC_P	7,105
Pr_P	2,345
Mn	1,315
postkrize	7,396

Zdroj: vlastní zpracování v SW Gretl, 2019

Ke zjištění multikolinearity byl použit test VIF (The variance inflation factor), jedná se o metodu, která detekuje závažnost lineární závislosti vysvětlujících proměnných. Hodnota VIF není ani v jednom případě vyšší než 10, což potvrzuje, že v modelu není výskyt multikolinearity.

5.5.2 Ekonometrické ověření – Testování autokorelace

K testu autokorelace je použit Breusch-Godfreyův test pro autokorelaci prvního řádu na hladině významnosti $\alpha = 0,05$. Pro testování autokorelace jsou stanoveny následující hypotézy:

H_0 : Nepřítomnost autokorelace reziduí 1. řádu

H_1 : Přítomnost autokorelace reziduí 1. řádu

Obrázek 6: Test autokorelace

```
LM test pro autokorelaci až do řádu 1 -  
Nulová hypotéza: žádná autokorelace  
Testovací statistika: LMF = 3,57283  
s p-hodnotou = P(F(1,19) > 3,57283) = 0,0740858
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledkem je p-hodnota 0,074, nelze tedy nulovou hypotézu zamítnout, protože je větší než hodnota významnosti $\alpha = 0,05$ a v modelu tedy není přítomna autokorelace reziduí.

5.5.3 Ekonometrické ověření – Test normality

Test normality náhodné složky je testován chí-kvadrát testem při hladině významnosti $\alpha = 0,05$. Pro test normality jsou stanoveny následující hypotézy:

H_0 : Rezidua mají normální rozdělení

H_1 : Rezidua nemají normální rozdělení


Obrázek 7: Test normality

```
Test normality reziduí -  
Nulová hypotéza: chyby jsou normálně rozdělené  
Testovací statistika: Chí-kvadrát(2) = 1,6405  
s p-hodnotou = 0,440321
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledná p-hodnota je 0,44, nelze tedy nulovou hypotézu zamítnout, protože p-hodnota je větší než hodnota hladiny významnosti $\alpha = 0,05$. Náhodná složka má tedy normální rozdělení.

Graf 15: Graf test normality



Zdroj: vlastní zpracování v SW Gretl, 2019

5.5.4 Ekonometrické ověření – Test heteroskedasticity

Pro test heteroskedasticity je využit Whitův test. Testování je prováděno opět na hladině významnosti $\alpha = 0,05$. Pro test heteroskedasticity jsou stanoveny následující hypotézy:

H_0 : Homoskedasticita reziduí

H_1 : Heteroskedasticita reziduí


Obrázek 8: Test heteroskedasticity

```
Whiteův test heteroskedasticity -
Nulová hypotéza: není zde heteroskedasticita
Testovací statistika: LM = 19,5978
s p-hodnotou = P(Chi-kvadrát(13) > 19,5978) = 0,105702
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledná p-hodnota = 0,105 je větší než hodnota $\alpha = 0,05$. Není tedy možné zamítnout nulovou hypotézu, což znamená nepřítomnost heteroskedasticity v modelu. Ekonometrický model má tedy homoskedasticitu reziduí (konstantní rozptyl reziduí).

Graf 16: Graf reziduí



Zdroj: vlastní zpracování v SW Gretl, 2019

Při grafickém vyhodnocení reziduí je patrné, že rezidua by mohla být heteroskedastická a to ve tvaru zvyšujícího a následně snižujícího se rozptylu, ale test potvrdil nepřítomnost heteroskedasticity.

Pro ověření byl použit Breusch-Paganův test heteroskedasticity, který potvrdil, že v modelu není heteroskedasticita přítomna.

Obrázek 9: Test heteroskedasticity kontrolní

```
Breusch-Paganův test heteroskedasticity -  
Nulová hypotéza: není zde heteroskedasticita  
Testovací statistika: LM = 8,6516  
s p-hodnotou = P(Chi-kvadrát(4) > 8,6516) = 0,070423
```

Zdroj: vlastní zpracování v SW Gretl, 2019

5.5.5 Ekonomické ověření – Test nonlinearity

U modelu byl rovněž proveden test nonlinearity při hladině významnosti $\alpha = 0,05$. Pro test nonlinearity jsou stanoveny následující hypotézy:

H_0 : Vztah je lineární

H_1 : Vztah není lineární

Obrázek 10: Test nelinearity

```
Test nelinearity (druhé mocniny) -  
Nulová hypotéza: vztah je lineární  
Testovací statistika: LM = 13,025  
s p-hodnotou = P(Chi-kvadrát(3) > 13,025) = 0,00458282
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledná p-hodnota je 0,0045, zamítáme tedy nulovou hypotézu o lineárním vztahu, protože p-hodnota je menší než hodnota hladiny významnosti $\alpha = 0,05$. Vztah tedy není lineární.

Obrázek 11: Test nelinearity podrobný

```
Pomocná regrese pro test nelinearity (druhé mocniny)  
OLS, za použití pozorování 1994-2018 (T = 25)  
Závisle proměnná: uhat
```

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-570,095	133,538	-4,269	0,0005	***
SpC_P	0,536219	0,672013	0,7979	0,4359	
Pr_P	0,0610684	0,0142694	4,280	0,0005	***
Mn	-1,04060	2,13978	-0,4863	0,6330	
postkrize	1,78265	2,21089	0,8063	0,4312	
sq_SpC_P	-0,00948345	0,0116062	-0,8171	0,4252	
sq_Pr_P	-1,64489e-06	3,83679e-07	-4,287	0,0005	***
sq_Mn	0,0766744	0,160094	0,4789	0,6381	

```
Neadjustovaný koeficient determinace = 0,521001  
Testovací statistika: TR^2 = 13,025,  
s p-hodnotou = P(Chi-kvadrát(3) > 13,025) = 0,00458282
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Při podrobnějším rozboru testu nelinearity, je možné si všimnout statisticky významných parametrů u lineárního a kvadratického členu produkce piva, což nasvědčuje tomu, že mezi spotřebou a produkcí piva je nelineární vztah a vzhledem ke znaménku lineárního a kvadratického členu produkce piva se jedná o vztah konkávní kvadratická funkce. Ovšem po přidání kvadratického členu produkce by sice mohlo dojít ke zlepšení modelu, nicméně interpretace parametru nelineární funkce je poněkud složitější, protože takové parametry se interpretují nejčastěji v určitém bodě, proto bude model o tento kvadratický člen modifikován až po provedení strukturální analýzy na základě pružností lineárního modelu.

5.5.6 Statistické ověření – Testování významnosti odhadnutých parametrů

U všech parametrů, kromě spotřebitelské ceny piva, vyšla p-hodnota menší než zvolená hladina významnosti $\alpha = 0,05$. U těchto parametrů se zamítá nulová hypotéza o statistické nevýznamnosti parametru a tyto parametry jsou tedy významné na hladině spolehlivosti 95 %. U parametru spotřebitelské ceny piva vyšla hodnota menší než hladina významnosti $\alpha = 0,1$ a zamítá se tak nulová hypotéza o statistické nevýznamnosti tohoto parametru a tento parametr je významný na hladině spolehlivosti 90 %.

Obrázek 12: Testování významnosti parametrů

	p-hodnota	
const	6,35e-08	***
SpC_P	0,0873	*
Pr_P	0,0085	***
Mn	0,0022	***
postkrize	0,0003	***

Zdroj: vlastní zpracování v SW Gretl, 2019

5.5.7 Statistické ověření – Shoda modelu s daty

R^2 – koeficient determinace

Podle koeficientu determinace $R^2 = 0,942$ jsou změny ve spotřebě piva vysvětleny z 94,2 % změnami nezávisle proměnných.

P-hodnota pro F-test 0,00000000000381 je menší než hladina významnosti $\alpha = 0,05$, zamítá se proto nulová hypotéza o statistické nevýznamnosti modelu jako celku a model je tedy významný na hladině 90 %.

5.5.8 Testování nové hypotézy

Zde bude pro provedení testování nové hypotézy o vlivu míry nezaměstnanosti na spotřebu pivu využito výsledků z odhadu parametrů ekonometrického modelu z podkapitoly 5.4.

H_0 : S růstem míry nezaměstnanosti se snižuje spotřeba piva

H_1 : S růstem míry nezaměstnanosti se zvyšuje spotřeba piva

Dle výsledků z podkapitoly 5.4 zamítáme nulovou hypotézu a přijímáme alternativní hypotézu, že s růstem míry nezaměstnanosti se zvyšuje spotřeba piva.

5.6 Ekonomické ověření modelu

γ_2 : Když se zvýší spotřebitelská cena piva o 1 Kč/l, spotřeba piva se sníží o 0,195983 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože se předpokládalo, že se zvýšením ceny piva se spotřeba piva snižuje.

γ_3 : Když se zvýší produkce piva o 1 tis. hl/rok, spotřeba piva se zvýší o 0,00239424 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože se předpokládalo, že se zvýšením produkce piva se spotřeba piva zvyšuje.

γ_4 : Když se zvýší míra nezaměstnanosti v ČR o 1 p.b., spotřeba piva se zvýší o 0,787823 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože se předpokládalo, že se zvýšením míry nezaměstnanosti se spotřeba piva zvyšuje.

γ_5 : Když nastalo postkrizové období, tak se spotřeba piva snížila o 8,77926 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože to odpovídalo výkyvu v grafu.

5.7 Aplikace ekonometrického modelu

5.7.1 Pružnosti (elasticita)

Pro výpočet pružností využijeme přesné metody. Vzorec pro výpočet přesné metody je následující: $E = \frac{\partial y}{\partial x_i} \frac{x_i}{\hat{y}}$

Tabulka 3: Výpočet pružností

	SpC_P	Pr_P	Mn	postkrize
$\partial y / \partial x_i$	-0,195983	0,00239424	0,787823	-8,77926
x_i prům	49,15	19404	2,2	1
\hat{y}	154,1429329	154,1429329	154,1429329	154,1429329
E	-0,04188	0,284512	0,030995	-0,024

Zdroj: vlastní zpracování v MS Excel, 2019

Interpretace:


Pokud se spotřebitelská cena piva zvýší o 1 %, potom se spotřeba piva sníží o 0,042 % ceteris paribus. Pokud se produkce piva zvýší o 1 %, potom se spotřeba piva zvýší o 0,285

% ceteris paribus. Pokud se míra nezaměstnanosti zvýší o 1 %, potom se se spotřeba piva zvýší o 0,031 % ceteris paribus.

Průměrná pružnost pro dummy proměnnou postkrize je 0,024 %, ale interpretace této hodnoty není úplně smysluplná, neboť jsou zprůměrovány mimo jiné nulové hodnoty před krizovým obdobím, proto je výsledkem interpretace nic neříkající informace. Z tohoto důvodu bude interpretován pouze průměrný vliv po nastání krize, při které došlo k trvalému poklesu ve spotřebě piva o 6 % ceteris paribus.

Největší vliv na danou vysvětlovanou proměnnou spotřebu piva má proměnná produkce piva, což je logické, jelikož spotřeba je z velké části podmíněna produkcí.

Graf 17: Pružnosti v jednotlivých letech



Zdroj: vlastní zpracování v MS Excel, 2019

Graf zachycuje pružnosti v jednotlivých letech, ze kterého je možné si všimnout, že největší vliv má produkce piva, která dominuje po celé sledované období. Zajímavá situace je z hlediska ceny, jejíž vliv po celou dobu roste. Vliv nezaměstnanosti ke konci sledovaného období spíše slábne.

5.8 Nelineární model

Nyní bude na základě testu nelinearity, který prokázal nelineární vztah, proveden odhad právě tohoto nelineárního modelu. Na základě nelineárního modelu budou vytvořeny prognózy.

V tomto případě se jedná o kvadratickou funkci, která je lineární v parametrech, a proto ji lze odhadnout opět pomocí metody BMNČ.

Zápis ekonometrického modelu:

$$y_{1t} = \gamma x_{1t} + \gamma x_{2t} + \gamma x_{3t} + \gamma x_{4t} + \gamma x_{3t}^2 + u_{1t}$$

Výstup odhadu parametrů ekonometrického modelu v SW Gretl je uveden níže:

Obrázek 13: Výstup 3. odhadu

Model 3: OLS, za použití pozorování 1994-2018 (T = 25)					
Závisle proměnná: Sp_P					
	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-425,812	124,903	-3,409	0,0029	***
SpC_P	-0,214164	0,0792906	-2,701	0,0142	**
Pr_P	0,0608223	0,0134522	4,521	0,0002	***
Mn	0,919598	0,165991	5,540	2,41e-05	***
postkrize	-8,07495	1,45855	-5,536	2,43e-05	***
sq_Pr_P	-1,57587e-06	3,62463e-07	-4,348	0,0003	***
Střední hodnota závisle proměnné		154,1432			
Sm. odchylka závisle proměnné		6,868858			
Součet čtverců reziduí		32,38444			
Sm. chyba regrese		1,305544			
Koeficient determinace		0,971401			
Adjustovaný koeficient determinace		0,963875			
F(5, 19)		129,0702			
P-hodnota (F)		5,51e-14			

Zdroj: vlastní zpracování v SW Gretl, 2019

V SW Gretl byly odhadnuty parametry ekonometrického modelu následovně:

$$y_{1t} = -425,812 - 0,214164x_{2t} + 0,0608223x_{3t} + 0,919598x_{4t} - 8,07495x_{5t} - 0,00000157587x_{3t}^2 + u_{1t}$$

Statistické a ekonometrické ověření

Ekonometrické ověření – Test autokorelace

K testu autokorelace je použit Breusch-Godfreyův test pro autokorelaci prvního řádu na hladině významnosti $\alpha = 0,05$. Pro testování autokorelace jsou stanoveny následující hypotézy:

H_0 : Nepřítomnost autokorelace reziduí 1. řádu

H_1 : Přítomnost autokorelace reziduí 1. řádu

Obrázek 14: Test autokorelace nelineární model

```
LM test pro autokorelaci až do řádu 1 -  
Nulová hypotéza: žádná autokorelace  
Testovací statistika: LMF = 1,77641  
s p-hodnotou = P(F(1,18) > 1,77641) = 0,199217
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledkem je p-hodnota 0,199, nelze tedy nulovou hypotézu zamítnout, protože je větší než hodnota významnosti $\alpha = 0,05$ a v modelu tedy není přítomna autokorelace reziduí. P-hodnota je tak znatelně lepší oproti p-hodnotě lineárního modelu.

Ekonometrické ověření – Test normality

Test normality náhodné složky je testován chí-kvadrát testem při hladině významnosti $\alpha = 0,05$. Pro test normality jsou stanoveny následující hypotézy:

H_0 : Rezidua mají normální rozdělení

H_1 : Rezidua nemají normální rozdělení


Obrázek 15: Test normality nelineární model

```
Test normality reziduí -  
Nulová hypotéza: chyby jsou normálně rozdělené  
Testovací statistika: Chí-kvadrát(2) = 2,09463  
s p-hodnotou = 0,350878
```

Zdroj: vlastní zpracování v SW Gretl, 2019

Výsledná p-hodnota je 0,35, nelze tedy nulovou hypotézu zamítnout, protože p-hodnota je větší než hodnota hladiny významnosti $\alpha = 0,05$. Náhodná složka má tedy normální rozdělení.

Graf 18: Graf test normality nelineární model



Zdroj: vlastní zpracování v SW Gretl, 2019

Ekonometrické ověření – Test heteroskedasticity

Pro test heteroskedasticity je využit Whitův test. Testování je prováděno opět na hladině významnosti $\alpha = 0,05$. Pro test heteroskedasticity jsou stanoveny následující hypotézy:

H_0 : Homoskedasticita reziduí

H_1 : Heteroskedasticita reziduí

Obrázek 16: Test heteroskedasticity nelineární model

```
Whiteův test heteroskedasticity -
Nulová hypotéza: není zde heteroskedasticita
Testovací statistika: LM = 18,9395
s p-hodnotou = P(Chi-kvadrát(18) > 18,9395) = 0,395558
```

Zdroj: vlastní zpracování v SW Gretl, 2019


Výsledná p-hodnota = 0,395 je větší než hodnota $\alpha = 0,05$. Není tedy možné zamítnout nulovou hypotézu, což znamená nepřítomnost heteroskedasticity v modelu.

Ekonometrický model má tedy homoskedasticitu reziduí (konstantní rozptyl reziduí). P-hodnota je tak opět znatelně lepší oproti p-hodnotě lineárního modelu.

Graf reziduí:

Dle grafu reziduí lze konstatovat, že výsledek rozptylu reziduí je znatelně příznivější, jelikož rezidua již nejsou na hranici heteroskedasticity, jako tomu bylo v lineárním modelu.


Graf 19: Graf reziduí nelineární model



Zdroj: vlastní zpracování v SW Gretl, 2019

Na základě lineárního a kvadratického parametru proměnné produkce piva, bylo možné parciální derivací rovno 0 spočítat hranici produkce piva, od které se již spotřeba s rostoucí produkcí nadále nezvyšuje. Touto hranicí je 19325,2 tis. hl/rok. Po překročení této hranice se pivo musí pravděpodobně vyvážet, protože se v České republice již nespotřebuje.

Graf 20: Hranice produkce piva



Zdroj: vlastní zpracování v MS Excel, 2019

Statistické ověření – Testování významnosti odhadnutých parametrů

U všech parametrů vyšla p-hodnota menší než zvolená hladina významnosti $\alpha = 0,05$. U těchto parametrů se zamítá nulová hypotéza o statistické nevýznamnosti parametru a tyto parametry jsou tedy významné na hladině spolehlivosti 95 %. Jedná se tedy o zlepšení u parametru spotřebitelské ceny piva, kde oproti lineárnímu modelu, vyšla p-hodnota menší než zvolená hladina významnosti $\alpha = 0,05$ a parametr spotřebitelské ceny piva je tedy také významný na hladině významnosti 95 %.

Obrázek 17: Testování významnosti parametrů nelineární model

	p-hodnota	
const	0,0029	***
SpC_P	0,0142	**
Pr_P	0,0002	***
Mn	2,41e-05	***
postkrize	2,43e-05	***
sq_Pr_P	0,0003	***

Zdroj: vlastní zpracování v SW Gretl, 2019

Statistické ověření – Shoda modelu s daty R^2 – koeficient determinace

Podle koeficientu determinace $R^2 = 0,971$ jsou změny ve spotřebě piva vysvětleny z 97,1 % změnami nezávisle proměnných.

P-hodnota pro F-test 0,0000000000000551 je menší než hladina významnosti $\alpha = 0,05$, zamítá se proto nulová hypotéza o statistické nevýznamnosti modelu jako celku a model je tedy významný na hladině významnosti 95 %. Jedná se tak o znatelné zlepšení oproti lineárnímu modelu, kde byl model statisticky významný pouze na hladině významnosti 90 %.

Ekonomické ověření modelu

γ_2 : Když se zvýší spotřebitelská cena piva o 1 Kč/l, spotřeba piva se sníží o 0,214 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože se předpokládalo, že se zvýšením ceny piva se spotřeba piva snižuje.

γ_3 : Tento parametr se nedá jednoduše interpretovat, proto bude interpretován v bodě průměrné produkce piva, který je 154,43 tis.hl/rok. Při této produkci by zvýšení produkce 1 tis. hl. se zvýší spotřeba piva o 0,06034 l/os/rok ceteris paribus.

γ_4 : Když se zvýší míra nezaměstnanosti v ČR o 1 p.b., spotřeba piva se zvýší o 0,919 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože se předpokládalo, že se zvýšením míry nezaměstnanosti se spotřeba piva zvyšuje.

γ_5 : Když nastalo postkrizové období, tak se spotřeba piva snížila o 8,075 l/os/rok ceteris paribus. Parametr lze považovat za ověřený, protože to odpovídalo výkyvu v grafu.

5.8.1 Prognózy

Prognózy byly vytvořeny na základě nelineárního modelu.

Pro ověření kvality prognózy poskytované výsledným modelem byla provedena ex-post prognóza na 3 poslední období, tedy na roky 2016-2018. Pro zajištění ex-post prognózy na tato období byly časové řady zkráceny o 3 poslední období, na základě této zkrácené datové základny byly odhadnuty parametry stejného modelu.

Obrázek 18: Odhad modelu pro ověření kvality prognózy

Model 4: OLS, za použití pozorování 1994-2015 (T = 22)				
Závisle proměnná: Sp_P				
	koeficient	směr. chyba	t-podíl	p-hodnota
const	-434,305	136,340	-3,185	0,0058 ***
SpC_P	-0,226907	0,0948693	-2,392	0,0294 **
Pr_P	0,0618010	0,0146967	4,205	0,0007 ***
Mn	0,972711	0,223166	4,359	0,0005 ***
postkrize	-8,01630	1,61218	-4,972	0,0001 ***
sq_Pr_P	-1,60396e-06	3,96403e-07	-4,046	0,0009 ***
Střední hodnota závisle proměnné		155,3268		
Sm. odchylka závisle proměnné		6,443956		
Součet čtverců reziduí		31,19522		
Sm. chyba regrese		1,396317		
Koeficient determinace		0,964226		
Adjustovaný koeficient determinace		0,953047		
F(5, 16)		86,25122		
P-hodnota (F)		5,40e-11		


Zdroj: vlastní zpracování v SW Gretl, 2019

Z výstupu je patrné, že po odebrání 3 posledních období se model nijak výrazně nezměnil z hlediska směru parametrů a jejich statistické významnosti. Model jako celek zůstal rovněž statisticky významný, i když hodnota adjustovaného koeficientu determinace se nepatrně snížila, což svědčí o celkové stabilitě modelu pro účely prognózy.

Do tohoto „zkráceného“ modelu byly dosazeny vynechané hodnoty vysvětlujících proměnných v zataženém období 2016-2018, čímž se získala prognóza ex-post, která je zobrazena v následujícím grafu.

Následující výstup zachycuje konkrétní prognózované hodnoty (bodová prognóza) v jednotlivých letech ex-post prognózy a rovněž jejich konfidenční intervaly s pravděpodobností 95 %.

Graf 21: ex-post prognóza spotřeby piva



Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 19: prognózované hodnoty ex-post prognózy

Pro 95% konfidenční intervaly, $t(16, 0,025) = 2,120$

Pozorování	Sp_P	předpověď	směr. chyba	95% konfidenční interval
2016	146,90	146,24	1,674	142,69 - 149,79
2017	144,30	144,42	1,838	140,52 - 148,31
2018	145,19	143,94	1,973	139,76 - 148,12

Statistiky vyhodnocující předpověď

Střední chyba	0,59881
Střední kvadratická chyba	0,67295
Odmocnina střední kvadratické chyby	0,82033
Střední absolutní chyba	0,6768
Střední procentuální chyba	0,4105
Střední absolutní procentuální chyba	0,46454

Zdroj: vlastní zpracování v SW Gretl, 2019

Samotná kvalita prognózy je měřena střední absolutní procentuální chybou, která je na úrovni 0,46454 %, což by mohlo nasvědčovat tomu, že má model dobré prognostické vlastnosti. K podobnému závěru lze dojít i při vyhodnocení normované odchylky, jejíž hodnota byla vypočtena na úrovni 0,12.

Pro stanovení ex-ante prognózy na 3 následující období bylo potřeba do ekonometrického modelu dosadit odhady budoucích hodnot vysvětlujících proměnných v letech 2019-2021. Pro odhad těchto hodnot přicházely v úvahu i trendové funkce, nicméně při jejich použití prognózované hodnoty nepůsobily příliš důvěryhodně, proto byla zvolena sofistikovanější metoda, a to použití autoregresních modelů (tzv. AR modelů)

Specifikace AR modelů byla provedena na základě úvahy, že maximální délka auto regrese (tedy působení proměnné sama na sebe) je 5 let. Delší proces nebyl předpokládán. Po odhadu AR (5) modelů, byla použita metoda postupného vyřazování zpožděných proměnných od statisticky nejméně významných parametrů až po kompletní statistickou významnost na hladině spolehlivosti 95 %. Následně byly tyto modely použity pro odhad budoucích hodnot použitých v ekonometrickém modelu.

Následující výstup zachycuje konkrétní prognózované hodnoty (bodová prognóza) v jednotlivých letech prognózy spotřebitelské ceny piva pomocí AR modelu a rovněž její konfidenční intervaly s pravděpodobností 95 %. Postupným vyřazováním zpožděných proměnných od statisticky nejméně významných parametrů až po kompletní statistickou významnost na hladině spolehlivosti 95 % bylo docíleno vyřazení všech zpožděných proměnných, kromě zpožděné proměnné o jedno období.


V roce 2019 vyšla hodnota prognózy spotřebitelské ceny piva 50,7846 Kč/l a její konfidenční interval s pravděpodobností 95 % v hodnotě 48,9437 – 52,6255 Kč/l.

V roce 2020 vyšla hodnota prognózy spotřebitelské ceny piva 52,4541 Kč/l a její konfidenční interval s pravděpodobností 95 % v hodnotě 49,8227 – 55,0856 Kč/l.

V roce 2021 vyšla hodnota prognózy spotřebitelské ceny piva 54,1593 Kč/l a její konfidenční interval s pravděpodobností 95 % v hodnotě 50,9017 – 57,4170 Kč/l.

Je tedy zřejmé, že spotřebitelská cena piva má v prognostickém horizontu vzrůstající tendenci.

Graf 22: Prognóza spotřebitelské ceny piva



Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 20: Autoregresní model pro SpC_P

Model 9: OLS, za použití pozorování 1995-2018 (T = 24)
 Závisle proměnná: SpC_P

	koeficient	směr. chyba	t-podíl	p-hodnota
const	0,584120	0,720752	0,8104	0,4264
SpC_P_1	1,02137	0,0218845	46,67	1,69e-023 ***

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 21: Prognózané hodnoty SpC_P

Pro 95% konfidenční intervaly, $t(22, 0,025) = 2,074$

Pozorování	SpC_P	předpověď	směr. chyba	95% konfidenční interval
2019	50,7846	0,887674	48,9437 -	52,6255
2020	52,4541	1,26885	49,8227 -	55,0856
2021	54,1593	1,57083	50,9017 -	57,4170

Zdroj: vlastní zpracování v SW Gretl, 2019

Následující výstup zachycuje konkrétní prognózané hodnoty (bodová prognóza) v jednotlivých letech prognózy produkce piva pomocí AR modelu a rovněž konfidenční intervaly s pravděpodobností 95 %. Postupným vyřazováním zpožděných proměnných od

statisticky nejméně významných parametrů až po kompletní statistickou významnost na hladině spolehlivosti 95 % bylo docíleno vyřazení všech zpožděných proměnných, kromě zpožděné proměnné o jedno období.


V roce 2019 vyšla hodnota prognózy produkce piva 18976,5 tis.hl./rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 17744,7 – 20208,4 tis.hl/rok.

V roce 2020 vyšla hodnota prognózy produkce piva 18730 tis.hl./rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 17307,8 – 20152,1 tis.hl/rok.

V roce 2021 vyšla hodnota prognózy produkce piva 18587,7 tis.hl./rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 17107,7 – 20067,8 tis.hl/rok.

Je tedy zřejmé, že produkce piva má v prognostickém horizontu klesající tendenci.

Graf 23: Prognóza produkce piva



Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 22: Autoregresní model produkce piva

Model 14: OLS, za použití pozorování 1995-2018 (T = 24)					
Závisle proměnná: Pr_P					
	koeficient	směr. chyba	t-podíl	p-hodnota	
const	7783,51	3435,38	2,266	0,0337	**
Pr_P_1	0,576842	0,188191	3,065	0,0057	***

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 23: Prognózané hodnoty produkce piva

Pro 95% konfidenční intervaly, $t(22, 0,025) = 2,074$					
Pozorování	Pr_P	předpověď	směr. chyba	95% konfidenční interval	
2019	18976,5	593,997	17744,7	-	20208,4
2020	18730,0	685,737	17307,8	-	20152,1
2021	18587,7	713,654	17107,7	-	20067,8

Zdroj: vlastní zpracování v SW Gretl, 2019


Následující výstup zachycuje konkrétní prognózané hodnoty (bodová prognóza) v jednotlivých letech prognózy míry nezaměstnanosti pomocí AR modelu a rovněž její konfidenční intervaly s pravděpodobností 95 %. Postupným vyřazováním zpožděných proměnných od statisticky nejméně významných parametrů až po kompletní statistickou významnost na hladině spolehlivosti 95 % bylo docíleno zachování zpožděných proměnných prvních dvou období.

Pozn: V době psaní této diplomové práce byla hodnota míry nezaměstnanosti pro rok 2019 již k dispozici, proto byla použita při prognózování.

V roce 2020 vyšla hodnota prognózy míry nezaměstnanosti 2,79762 % a její konfidenční interval s pravděpodobností 95 % v hodnotě 0,927534 – 4,66771 %.

V roce 2021 vyšla hodnota prognózy míry nezaměstnanosti 4,03268 % a její konfidenční interval s pravděpodobností 95 % v hodnotě 0,826455 – 7,23890 %.

Graf 24: Prognóza obecné míry nezaměstnanosti



Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 24: Autoregresní model pro Mn

Model 18: OLS, za použití pozorování 1996-2019 (T = 24)
 Závisle proměnná: Mn

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	1,37920	0,709415	1,944	0,0654	*
Mn_1	1,39263	0,179442	7,761	1,33e-07	***
Mn_2	-0,621295	0,195015	-3,186	0,0044	***

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 25: Prognózané hodnoty Mn

Pro 95% konfidenční intervaly, $t(21, 0,025) = 2,080$

Pozorování	Mn	předpověď	směr. chyba	95% konfidenční interval
2020	2,79762	0,899248	0,927534	4,66771
2021	4,03268	1,54174	0,826455	7,23890

Zdroj: vlastní zpracování v SW Gretl, 2019

Na základě předešlých provedených prognóz v této diplomové práci bylo možné provést ex-ante prognózu spotřeby piva na 3 následující období.

Obrázek 26: Odhad modelu pro ex-ante prognózu spotřeby piva

Model 19: OLS, za použití pozorování 1994-2018 (T = 25)					
Závisle proměnná: Sp_P					
	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-425,812	124,903	-3,409	0,0029	***
SpC_P	-0,214164	0,0792906	-2,701	0,0142	**
Pr_P	0,0608223	0,0134522	4,521	0,0002	***
Mn	0,919598	0,165991	5,540	2,41e-05	***
postkrize	-8,07495	1,45855	-5,536	2,43e-05	***
sq_Pr_P	-1,57587e-06	3,62463e-07	-4,348	0,0003	***
Střední hodnota závisle proměnné		154,1432			
Sm. odchylka závisle proměnné		6,868858			
Součet čtverců reziduí		32,38444			
Sm. chyba regrese		1,305544			
Koeficient determinace		0,971401			
Adjustovaný koeficient determinace		0,963875			
F(5, 19)		129,0702			
P-hodnota (F)		5,51e-14			

Zdroj: vlastní zpracování v SW Gretl, 2019


Následující výstup zachycuje konkrétní prognózované hodnoty (bodová prognóza) v jednotlivých letech ex-ante prognózy spotřeby piva a rovněž její konfidenční intervaly s pravděpodobností 95 %.

V roce 2019 vyšla hodnota prognózy spotřeby piva 143,790 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,523 – 147,057 l/os/rok.

V roce 2020 vyšla hodnota prognózy spotřeby piva 143,820 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,461 – 147,179 l/os/rok.

V roce 2021 vyšla hodnota prognózy spotřeby piva 144,304 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,862 – 147,746 l/os/rok.

Graf 25: ex-ante prognóza spotřeby piva



Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 27: Prognózované hodnoty spotřeby piva

Pro 95% konfidenční intervaly, $t(19, 0,025) = 2,093$

Pozorování	Sp_P	předpověď	směr. chyba	95% konfidenční interval
2019	143,790	1,56093	140,523 -	147,057
2020	143,820	1,60508	140,461 -	147,179
2021	144,304	1,64460	140,862 -	147,746

Zdroj: vlastní zpracování v SW Gretl, 2019

Závěr

Nejprve byly na základě ekonomické teorie definovány možné determinanty pro tuzemskou spotřebu piva. Determinanty byly zvoleny proměnné spotřebitelská cena piva, produkce piva, míra nezaměstnanosti, míra inflace, platební bilance, průměrná mzda a spotřebitelská cena vína.

V této diplomové práci byl odhadován jednorovnicový ekonometrický model pomocí běžné metody nejmenších čtverců v SW Gretl. Do modelu byla vzhledem k velkému výkyvu, respektive propadu hodnot vysvětlované endogenní proměnné po určité časové období, dodatečně přidána umělá (dummy) proměnná, která charakterizuje možnou příčinu tohoto propadu. Po samotném odhadu modelu bylo provedeno ověření, tedy verifikace modelu. Součástí verifikace modelu byl test linearity, který prokázal, že mezi vysvětlovanou endogenní proměnnou a vysvětlující proměnnou produkce piva je nelineární vztah, a to konkrétně, že se jedná o konkávní kvadratickou funkci.

Po odhadu tohoto nelineárního modelu se při ověřování modelu projevilo značné zlepšení, a to jak ve statistické významnosti celého modelu, kdy podle koeficientu determinace jsou změny ve vysvětlované endogenní proměnné vysvětleny již z 97,1 % změnami nezávisle proměnných, tak ve statistické významnosti jednotlivých parametrů. Znatelné zlepšení bylo zaznamenáno také při ekonometrickém ověřování, kdy byl například výsledek rozptylu reziduí znatelně příznivější, jelikož rezidua již nebyla na hranici heteroskedasticity, jako tomu bylo v modelu lineárním. Dále bylo provedeno testování nové hypotézy o vlivu míry nezaměstnanosti na spotřebu piva a dle výsledku testování lze přijmout tuto novou hypotézu, dle které s růstem míry nezaměstnanosti, se zvyšuje také spotřeba piva.

Model je možné na základě výsledků při ověřování, považovat za vhodný k aplikaci. Aplikace modelu byla založena na výpočtu a interpretaci elasticit, a především na prognóze vysvětlované endogenní proměnné. Hlavní cíl této diplomové práce bylo tedy kromě provedení kvantitativní analýzy tuzemské spotřeby piva, zároveň provedení prognózy vysvětlované endogenní proměnné, tedy spotřeby piva v České republice pro 3 následující období, respektive roky.

Před samotnou ex-ante prognózou vysvětlované endogenní proměnné, bylo potřeba pro ověření kvality prognózy (resp. verifikaci prognostických vlastností) poskytované výsledným modelem, nejprve provést ex-post prognózu. Ta byla provedena na 3 poslední období, tedy na roky 2016-2018. Samotná kvalita prognózy je na úrovni 0,46454 %, což nasvědčuje tomu, že má model dobré prognostické vlastnosti.

Pro stanovení ex-ante prognózy vysvětlované endogenní proměnné na 3 následující období bylo dále potřeba do ekonometrického modelu dosadit odhady budoucích hodnot vysvětlujících proměnných v letech 2019-2021. Na základě předešlých provedených prognóz bylo již možné provést ex-ante prognózu pro vysvětlovanou endogenní proměnnou spotřebu piva na 3 následující období, tedy na roky 2019-2021. Na rok 2019 byla hodnota prognózy spotřeby piva stanovena na 143,790 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,523 – 147,057 l/os/rok. Na rok 2020 byla hodnota prognózy spotřeby piva stanovena na 143,820 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,461 – 147,179 l/os/rok. Na rok 2021 byla hodnota prognózy spotřeby piva stanovena na 144,304 l/os/rok a její konfidenční interval s pravděpodobností 95 % v hodnotě 140,862 – 147,746 l/os/rok. Z výsledků prognóz vyplývá, že spotřeba piva klesne, což by mohlo vzhledem k faktu, že se jedná kromě roku 2011 o nejnižší hodnoty ve sledovaném období spotřeby, poukazovat například na, prozatím nespécifikovanou, blížící se krizi. K takovému závěru je ale stále ještě brzy a pro případné přijetí této nové hypotézy, by bylo potřeba zahrnout data z let následujících.

Velmi zajímavého výsledku bylo dosaženo na základě nelineárního vztahu spotřeby a produkce piva, kde bylo možné vypočítat hranici produkce piva, od které se již tuzemská spotřeba s rostoucí produkcí nadále nezvyšuje. Touto hranicí je 19325,2 tis. hl/rok. Po překročení této hranice, se pivo musí pravděpodobně pouze vyvážet, protože se v České republice již nespécifikuje. Výrobci by tedy na základě těchto informací mohli zefektivnit svou výrobu.

6 Seznam použitých zdrojů

Literatura

ASTERIOU, Dimitrios a HALL, Stephen G. Applied Econometrics: A Modern Approach. Palgrave Macmillan. New York. 2007. 397 s. ISBN 978-0230506404

BALTAGI, Badi H. Econometrics. Berlin: Springer Science & Business Media. 2008. 408 s. ISBN 978-3-540-76515-8.

BASAŘOVÁ, Gabriela. HLAVÁČEK, Ivo. České Pivo. Praha: Nuga. 1999. 230 s. ISBN 80-85903-08-3

CIPRA, Tomáš. Finanční ekonometrie. Praha: Ekopress. 2008. 538 s. ISBN 978-80-86929-43-9.

CIPRA, Tomáš. Finanční ekonometrie. 2. vydání: Ekopress. 2013. 538 s. ISBN 978-80-86929-93-4

FIALA, Petr. Úvod do ekonometrie. Praha: ČVUT v Praze. Fakulta jaderná a fyzikálně inženýrská. 2008. 173 s. ISBN 978-80-01-04004-1.

GUJARATI, Damodar N. Basic Econometrics. 4th edition. Singapore: Tata McGraw Hill. 2004. 1032 s. 978-0070597938

GUJARATI, Damodar N. a Dawn C. PORTER. Basic econometrics. 5th ed. Boston: McGraw-Hill Education. 2009. 944 s. ISBN 978-0073375779

HANČLOVÁ, Jana. Ekonometrické modelování: Klasické přístupy s aplikacemi. 1. vydání. Praha: Professional Publishing. 2012. 214 s. ISBN 978-80-7431-088-1

HOLMAN, Robert. Ekonomie. Praha: C. H. Beck. 1999. 726 s. 80-7179-255-1.

HOLMAN, Robert. Makroekonomie. 1. vydání. Praha: C. H. Beck. 2004. 242 s. ISBN 80-7179-764-2.

HUŠEK, Roman a WALTER, Jaromír. Ekonometrie. Praha: Nakladatelství technické literatury, 1976.

- HUŠEK, Roman. Základy ekonometrie. Praha: VŠE. 1992. 220 s. ISBN 80-7079-566-2
- HUŠEK, Roman. Ekonometrická analýza. Praha: Ekopress, 1999. 303 s. ISBN 80-86119-19-X
- HUŠEK, Roman. Ekonometrická analýza. 1. vydání. Praha: Oeconomica. 2007. 368 s. ISBN 978-80-245-1300-3
- HUŠEK, Roman. Aplikovaná ekonometrie: teorie a praxe. Praha: Oeconomica. 2009. 346 s. ISBN 978-80-245-1623-3
- CHLÁDEK, Ladislav. Pivovarnictví. Praha: Grada. 2007. 218 s. ISBN 978-80-247-1616-9
- KLEIN, Lawrence R. Úvod do ekonometrie. I. Nakladatelství politické literatury v Praze. 1966. 389 s.
- KOLIBOVÁ, Helena a KUBICOVÁ, Alina. Trh práce a politika zaměstnanosti: distanční studijní opora. Karviná: Slezská univerzita v Opavě, Obchodně podnikatelská fakulta v Karviné. 2005. 233 s. ISBN 80-7248-321-8
- KRKOŠKOVÁ, Šárka. Aj. Základy ekonometrie v příkladech. 2. vydání. Praha: Oeconomica. 2010. 276 s. 978-80-245-1708-7.
- MUKRAS, M. S. Elementary Econometrics: Theory. Application and Policy. Keyna: East African Publishers. 1993. 647 s. ISBN 978-9966465573
- SCHILLER, B. R. Makroekonomie dnes. BizBooks. 2004. 432 s. ISBN 80-251-0169
- STUDENMUND, A. H. Using econometrics: A Practical Guide. 6th edition. Harlow: Pearson education. 2014. 560 s. ISBN 978-1292021270
- TINTNER, Gerhard. Methodology of Mathematical Economics and Econometrics. 6th edition. Chicago: University of Chicago Press. 1968. 113 s. ISBN 978-0226804439
- TVRDOŇ, Jiří. Ekonometrie. Praha: Credit – PEF ČZU v Praze. 2000. 225 s. ISBN 80-213-0620-3

TVRDOŇ, Jiří. Ekonometrie. 5. vydání. Praha: Česká zemědělská univerzita. 2014. 225 s. ISBN 978-80213-0819

WOOLDRIDGE, Jeffrey M. Introductory Econometrics: A Modern Approach. 4th edition. USA: South-Western. 2008. 888 s. ISBN 978-0324660548

Internetové zdroje

ČADIL, Jan. (2011). Analýza nákladů veřejných rozpočtů na středního nezaměstnaného. [online]. [cit. 2019-09-15]. Dostupné z: http://server.universium.cz/publikace/10_analyza_nakladu_ver_rozpocetu_stredni_nezamestnany.pdf

České pivo ©2020. Muži vypijí takřka osm púllitrů piva týdně, ženy skoro tři. ceske-pivo.cz [online]. [cit. 2019-09-08]. Dostupné z: <http://ceske-pivo.cz/tz/muzi-vypiji-takrka-osm-pullitru-piva-tydne-zeny-skoro-tri>

Český statistický úřad ©2020. czso.cz [online] [cit. 2019-07-28] Dostupné z: <https://www.czso.cz/>

Český statistický úřad ©2020. Veřejná databáze. vdb.czso.cz [online] [cit. 2019-07-28] Dostupné z: <https://vdb.czso.cz/vdbvo2/faces/cs/index.jsf?page=home>

DANEL, Roman. (2004). Predikce časové řady pomocí autoregresního modelu. [online]. [cit. 2019-11-24]. Dostupné z: http://homel.vsb.cz/~dan11/publikace/Danel_Autoregresni_model_predikce_casovych_rad.pdf

Echo24 ©2020. Příjemné srovnání. Nejlevnější pivo je v Praze. echo24.cz [online]. [cit. 2019-09-22]. Dostupné z: <https://echo24.cz/a/wkD2P/prijemne-srovnani-nejlevnejsi-pivo-je-v-praze>

GOLDBERGER, Arthur R. (1964). Econometric Theory. Wiley [online]. [cit. 2019-09-15]. Dostupné z: https://www.researchgate.net/publication/30775595_Arthur_S_Goldberger_Econometric_Theory_Wiley_New_York_c_1964

HOLODNY, Helena. (2017). Here's how much it costs to grab a beer around the world. Business Insider [online]. [cit. 2019-09-22]. Dostupné z: <https://www.businessinsider.com/cost-of-beer-around-the-world-2017-5>

The Brewers of Europe ©2018. Beer statistics. Brewersofeurope.org [online]. [cit. 2019-09-23]. Dostupné z: <https://brewersofeurope.org/uploads/mycms-files/documents/publications/2018/EU-beer-statistics-2018-web.pdf>

VINOPAL, Jiří. (2018). Pivo v české společnosti v roce 2018. CVVM SÚ AV ČR. [online] [cit. 2019-09-21]. Dostupné z: https://cvvm.soc.cas.cz/media/com_form2content/documents/c2/a4749/f9/OR181113a.pdf

7 Přílohy

Příloha 1: Datová tabulka použitých proměnných.....	I
Příloha 2: Pomocné grafy ke spotřebě piva	II
Příloha 3: Přesné znění otázek výzkumu provedeného CVVM SOÚ AV ČR	IV
Příloha 4: Výstup dalších odhadů	V

Příloha 1: Datová tabulka použitých proměnných


Tabulka 4: Datová tabulka

období	spotřeba piva [l/os/rok]	spotřebitelská cena piva [Kč/rok]	produkce piva [tis. hl/rok]	míra nezaměstnanosti [%]
1994	156,7	18,78	17876	4,3
1995	156,9	18,76	17687	4
1996	157,3	20,12	18057	3,9
1997	161,4	21,3	18558	4,8
1998	161,1	23,24	18290	6,5
1999	159,8	24,53	17946	8,7
2000	159,9	25,8	17796	8,8
2001	156,9	26,75	17734	8,1
2002	159,9	28,14	17987	7,3
2003	161,7	29,02	18216	7,8
2004	160,5	30,19	18596	8,3
2005	163,5	30,92	18885	7,9
2006	159,1	31,08	20134	7,1
2007	159,1	33,13	18627	5,3
2008	156,57	35,61	19213	4,4
2009	150,68	35,59	18053	6,7
2010	144,43	38	16896	7,3
2011	142,47	38,2	17127	6,7
2012	148,6	40,05	18024	7
2013	147,02	41,16	18145	7
2014	147,01	41,66	18182	6,1
2015	146,61	41,68	18540	5
2016	146,9	44,8	18725	4
2017	144,3	46,53	18547	2,9
2018	145,19	49,15	19404	2,2

Zdroj: vlastní zpracování dle dat z ČSÚ, 2019


Příloha 2: Pomocné grafy ke spotřebě piva

Obrázek 28: Celková spotřeba piva za rok v litrech



Zdroj: Brewersofeurope.com, 2019

Obrázek 29: Cena piva v jednotlivých zemích



Zdroj: Deutsche Bank, Business Insider, 2019

Otázka č.1: „Pijete někdy pivo? (Ano – ne)“

Otázka č.2: „Jaké množství piva přibližně vypijete za týden? Kdybyste to přepočítal na půllitry, kolik by to tak průměrně bylo?“

Otázka č.3: V takto koncipované analýze nejde o odhad průměrné spotřeby populace, nýbrž o sledování trendu v množství a způsobech konzumace piva u těch, kteří jej pijí.

Otázka č.4: „Jak často běžně pivo pijete? Teď nezáleží na množství, zajímá nás, v kolika dnech v týdnu průměrně se nějakého piva napijete.“

Otázka č.5: „Pocitujete Vy osobně hrdost nebo stud, když se dozvídáte, že se v České republice ze všech zemí vypije nejvíce piva na hlavu? Pocitujete rozhodně hrdost, spíše hrdost, tak trochu obojí, spíše stud, rozhodně stud, je Vám to jedno?“

Otázka č.5: „Pocitujete Vy osobně hrdost nebo stud, když se dozvídáte, že se v České republice ze všech zemí vypije nejvíce piva na hlavu? Pocitujete rozhodně hrdost, spíše hrdost, tak trochu obojí, spíše stud, rozhodně stud, je Vám to jedno?“

Příloha 4: Výstup dalších odhadů

Obrázek 30: Výstup autoregresního modelu SpC_P 1

Model 5: OLS, za použití pozorování 1999-2018 (T = 20)

Závisle proměnná: SpC_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	2,18058	1,76879	1,233	0,2379	
SpC_P_1	0,590442	0,289717	2,038	0,0609	*
SpC_P_2	0,209027	0,322729	0,6477	0,5277	
SpC_P_3	-0,222723	0,338427	-0,6581	0,5211	
SpC_P_4	0,175486	0,381093	0,4605	0,6522	
SpC_P_5	0,269704	0,335557	0,8038	0,4350	
Střední hodnota závisle proměnné			35,59950		
Sm. odchylka závisle proměnné			7,248197		
Součet čtverců reziduí			12,76421		
Sm. chyba regrese			0,954845		
Koeficient determinace			0,987213		
Adjustovaný koeficient determinace			0,982646		
F(5, 14)			216,1664		
P-hodnota (F)			9,79e-13		
Logaritmus věrohodnosti			-23,88790		
Akaikovo kritérium			59,77581		
Schwarzovo kritérium			65,75020		
Hannan-Quinnovo kritérium			60,94207		
rho (koeficient autokorelace)			-0,074904		
Durbin-Watsonova statistika			2,052157		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 14 (SpC_P_4)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 31: Výstup autoregresního modelu SpC_P 2

Model 6: OLS, za použití pozorování 1999-2018 (T = 20)

Závisle proměnná: SpC_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	1,94427	1,64764	1,180	0,2564	
SpC_P_1	0,605913	0,280102	2,163	0,0471	**
SpC_P_2	0,243988	0,305321	0,7991	0,4367	
SpC_P_3	-0,154688	0,296368	-0,5219	0,6093	
SpC_P_5	0,329569	0,301114	1,094	0,2910	
Střední hodnota závisle proměnné			35,59950		
Sm. odchylka závisle proměnné			7,248197		
Součet čtverců reziduí			12,95754		
Sm. chyba regrese			0,929428		
Koeficient determinace			0,987019		
Adjustovaný koeficient determinace			0,983557		
F(4, 15)			285,1332		
P-hodnota (F)			5,95e-14		
Logaritmus věrohodnosti			-24,03823		
Akaikovo kritérium			58,07645		
Schwarzovo kritérium			63,05511		
Hannan-Quinnovo kritérium			59,04834		
rho (koeficient autokorelace)			-0,083205		
Durbin-Watsonova statistika			2,078621		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 13 (SpC_P_3)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 32: Výstup autoregresního modelu SpC_P 3
 Model 7: OLS, za použití pozorování 1999-2018 (T = 20)
 Závisle proměnná: SpC_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	1,80867	1,58961	1,138	0,2720	
SpC_P_1	0,595173	0,272919	2,181	0,0445	**
SpC_P_2	0,177658	0,271231	0,6550	0,5218	
SpC_P_5	0,254206	0,258160	0,9847	0,3394	
Střední hodnota závisle proměnné			35,59950		
Sm. odchylka závisle proměnné			7,248197		
Součet čtverců reziduí			13,19287		
Sm. chyba regrese			0,908050		
Koeficient determinace			0,986783		
Adjustovaný koeficient determinace			0,984305		
F(3, 16)			398,1940		
P-hodnota(F)			3,09e-15		
Logaritmus věrohodnosti			-24,21822		
Akaikovo kritérium			56,43643		
Schwarzovo kritérium			60,41936		
Hannan-Quinnovo kritérium			57,21394		
rho (koeficient autokorelace)			-0,062662		
Durbin-Watsonova statistika			1,988836		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 12 (SpC_P_2)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 33: Výstup autoregresního modelu SpC_4 1
 Model 8: OLS, za použití pozorování 1999-2018 (T = 20)
 Závisle proměnná: SpC_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	2,06828	1,51332	1,367	0,1895	
SpC_P_1	0,690301	0,227155	3,039	0,0074	***
SpC_P_5	0,333728	0,223972	1,490	0,1545	
Střední hodnota závisle proměnné			35,59950		
Sm. odchylka závisle proměnné			7,248197		
Součet čtverců reziduí			13,54663		
Sm. chyba regrese			0,892671		
Koeficient determinace			0,986429		
Adjustovaný koeficient determinace			0,984832		
F(2, 17)			617,8271		
P-hodnota(F)			1,34e-16		
Logaritmus věrohodnosti			-24,48283		
Akaikovo kritérium			54,96566		
Schwarzovo kritérium			57,95285		
Hannan-Quinnovo kritérium			55,54879		
rho (koeficient autokorelace)			-0,217231		
Durbinovo h			-6,760979		

zde je poznámka o zkratkách statistik modelu

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 34: Výstup autoregresního modelu Pr_P 1

Model 10: OLS, za použití pozorování 1999–2018 (T = 20)

Závisle proměnná: Pr_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	18995,1	7474,52	2,541	0,0235	**
Pr_P_1	0,400312	0,281113	1,424	0,1763	
Pr_P_2	0,126955	0,293511	0,4325	0,6719	
Pr_P_3	-0,116425	0,293863	-0,3962	0,6979	
Pr_P_4	-0,234286	0,292160	-0,8019	0,4360	
Pr_P_5	-0,214692	0,277641	-0,7733	0,4522	
Střední hodnota závisle proměnné			18338,87		
Sm. odchylka závisle proměnné			745,0472		
Součet čtverců reziduí			5781917		
Sm. chyba regrese			642,6462		
Koeficient determinace			0,451785		
Adjustovaný koeficient determinace			0,255994		
F(5, 14)			2,307488		
P-hodnota(F)			0,099940		
Logaritmus věrohodnosti			-154,1239		
Akaikovo kritérium			320,2478		
Schwarzovo kritérium			326,2222		
Hannan-Quinnovo kritérium			321,4141		
rho (koeficient autokorelace)			-0,029333		
Durbin-Watsonova statistika			1,831871		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 18 (Pr_P_3)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 35: Výstup autoregresního modelu Pr_P 2

Model 11: OLS, za použití pozorování 1999–2018 (T = 20)

Závisle proměnná: Pr_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	19043,9	7260,46	2,623	0,0192	**
Pr_P_1	0,387240	0,271211	1,428	0,1738	
Pr_P_2	0,0800164	0,260882	0,3067	0,7633	
Pr_P_4	-0,281590	0,259047	-1,087	0,2942	
Pr_P_5	-0,226517	0,268163	-0,8447	0,4115	
Střední hodnota závisle proměnné			18338,87		
Sm. odchylka závisle proměnné			745,0472		
Součet čtverců reziduí			5846743		
Sm. chyba regrese			624,3259		
Koeficient determinace			0,445639		
Adjustovaný koeficient determinace			0,297809		
F(4, 15)			3,014542		
P-hodnota(F)			0,052019		
Logaritmus věrohodnosti			-154,2354		
Akaikovo kritérium			318,4708		
Schwarzovo kritérium			323,4495		
Hannan-Quinnovo kritérium			319,4427		
rho (koeficient autokorelace)			-0,010731		
Durbin-Watsonova statistika			1,807759		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 17 (Pr_P_2)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 36: Výstup autoregresního modelu Pr_P 3
 Model 12: OLS, za použití pozorování 1999–2018 (T = 20)
 Závisle proměnná: Pr_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	19350,2	6984,87	2,770	0,0137	**
Pr_P_1	0,431610	0,222820	1,937	0,0706	*
Pr_P_4	-0,254238	0,236228	-1,076	0,2978	
Pr_P_5	-0,234905	0,259103	-0,9066	0,3781	
Střední hodnota závisle proměnné		18338,87			
Sm. odchylka závisle proměnné		745,0472			
Součet čtverců reziduí		5883412			
Sm. chyba regrese		606,3936			
Koeficient determinace		0,442162			
Adjustovaný koeficient determinace		0,337567			
F(3, 16)		4,227388			
P-hodnota(F)		0,022196			
Logaritmus věrohodnosti		-154,2979			
Akaikovo kritérium		316,5958			
Schwarzovo kritérium		320,5788			
Hannan-Quinnovo kritérium		317,3734			
rho (koeficient autokorelace)		-0,064985			
Durbinovo h		-1,189863			

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 20 (Pr_P_5)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 37: Výstup autoregresního modelu Pr_P 4
 Model 13: OLS, za použití pozorování 1998–2018 (T = 21)
 Závisle proměnná: Pr_P

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	15489,1	5433,34	2,851	0,0106	**
Pr_P_1	0,511862	0,195146	2,623	0,0172	**
Pr_P_4	-0,358276	0,194424	-1,843	0,0819	*
Střední hodnota závisle proměnné		18336,55			
Sm. odchylka závisle proměnné		726,2605			
Součet čtverců reziduí		6277694			
Sm. chyba regrese		590,5597			
Koeficient determinace		0,404906			
Adjustovaný koeficient determinace		0,338785			
F(2, 18)		6,123671			
P-hodnota(F)		0,009360			
Logaritmus věrohodnosti		-162,1816			
Akaikovo kritérium		330,3632			
Schwarzovo kritérium		333,4968			
Hannan-Quinnovo kritérium		331,0433			
rho (koeficient autokorelace)		-0,136084			
Durbinovo h		-1,246536			

zde je poznámka o zkratkách statistik modelu

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 38: Výstup autoregresního modelu Mn 1
 Model 15: OLS, za použití pozorování 1999-2019 (T = 21)
 Závisle proměnná: Mn

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	0,709987	1,38313	0,5133	0,6152	
Mn_1	1,58663	0,255218	6,217	1,65e-05	***
Mn_2	-1,13147	0,469395	-2,410	0,0292	**
Mn_3	0,669900	0,528456	1,268	0,2242	
Mn_4	-0,310662	0,468734	-0,6628	0,5175	
Mn_5	0,0530018	0,276015	0,1920	0,8503	
Střední hodnota závisle proměnné			6,219048		
Sm. odchylka závisle proměnné			2,077888		
Součet čtverců reziduí			13,71135		
Sm. chyba regrese			0,956081		
Koeficient determinace			0,841216		
Adjustovaný koeficient determinace			0,788288		
F(5, 15)			15,89363		
P-hodnota(F)			0,000016		
Logaritmus věrohodnosti			-25,32157		
Akaikovo kritérium			62,64315		
Schwarzovo kritérium			68,91028		
Hannan-Quinnovo kritérium			64,00328		
rho (koeficient autokorelace)			-0,099193		
Durbin-Watsonova statistika			2,020171		

zde je poznámka o zkratkách statistik modelu

Pomíne-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 15 (Mn_5)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 39: Výstup autoregresního modelu Mn 2
 Model 16: OLS, za použití pozorování 1998-2019 (T = 22)
 Závisle proměnná: Mn

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	1,26455	1,08602	1,164	0,2603	
Mn_1	1,59795	0,235185	6,794	3,13e-06	***
Mn_2	-1,18298	0,419357	-2,821	0,0118	**
Mn_3	0,659079	0,423122	1,558	0,1377	
Mn_4	-0,285411	0,254978	-1,119	0,2786	
Střední hodnota závisle proměnné			6,231818		
Sm. odchylka závisle proměnné			2,028696		
Součet čtverců reziduí			14,49591		
Sm. chyba regrese			0,923418		
Koeficient determinace			0,832277		
Adjustovaný koeficient determinace			0,792813		
F(4, 17)			21,08941		
P-hodnota(F)			2,07e-06		
Logaritmus věrohodnosti			-26,62771		
Akaikovo kritérium			63,25543		
Schwarzovo kritérium			68,71064		
Hannan-Quinnovo kritérium			64,54051		
rho (koeficient autokorelace)			-0,022149		
Durbin-Watsonova statistika			1,980927		

zde je poznámka o zkratkách statistik modelu

Pomíne-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 14 (Mn_4)

Zdroj: vlastní zpracování v SW Gretl, 2019

Obrázek 40: Výstup autoregresního modelu Mn 3
 Model 17: OLS, za použití pozorování 1997-2019 (T = 23)
 Závisle proměnná: Mn

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	0,964307	0,902984	1,068	0,2989	
Mn_1	1,52187	0,225824	6,739	1,94e-06	***
Mn_2	-0,936348	0,359720	-2,603	0,0175	**
Mn_3	0,253122	0,245327	1,032	0,3151	
Střední hodnota závisle proměnné			6,169565		
Sm. odchylka závisle proměnné			2,004412		
Součet čtverců reziduí			15,92953		
Sm. chyba regrese			0,915640		
Koeficient determinace			0,819779		
Adjustovaný koeficient determinace			0,791323		
F(3, 19)			28,80863		
P-hodnota(F)			2,81e-07		
Logaritmus věrohodnosti			-28,41141		
Akaikovo kritérium			64,82283		
Schwarzovo kritérium			69,36480		
Hannan-Quinnovo kritérium			65,96512		
rho (koeficient autokorelace)			0,075767		
Durbin-Watsonova statistika			1,809176		

zde je poznámka o zkratkách statistik modelu

Pomine-li se konstanta, p-hodnota byla nejvyšší pro proměnnou 13 (Mn_3)

Zdroj: vlastní zpracování v SW Gretl, 2019